



ANÁLISE DE WAVELET NA DETECÇÃO E DIAGNÓSTICO DE OSCILAÇÕES EM MALHAS DE CONTROLE DE PROCESSOS

Danilo Dias Tannus

Dissertação de Mestrado apresentada ao Programa
de Pós-Graduação em Engenharia Elétrica –
PROEE, da Universidade Federal de Sergipe,
como parte dos requisitos necessários à obtenção
do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Oscar A. Z. Sotomayor

São Cristóvão - SE, Brasil

Dezembro de 2015



UNIVERSIDADE FEDERAL DE SERGIPE
PRÓ-REITORIA DE PÓS-GRADUAÇÃO E PESQUISA
COORDENAÇÃO DE PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

TERMO DE APROVAÇÃO

"Análise de Wavelet na Detecção e Diagnóstico de Oscilações em Malhas de Controle de Processos"

Discente:

Danilo Dias Tannus

Orientador:

Prof. Dr. Oscar A. Z. Sotomayor

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica – PROEE, da Universidade Federal de Sergipe, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Elétrica.

Aprovada pela banca examinadora composta por:

Prof. Dr. Carlos Alberto Villacorta Cardoso (PROEE/UFS)

Presidente

Prof. Dr. Douglas Bressan Riffel (DMEC/UFS)

Examinador Externo

Prof. Dr. Marcus Vinícius Americano da Costa Filho (DEQ/UFBA)

Examinador Externo

Cidade Universitária "Prof. José Aloísio de Campos", 16 de dezembro de 2015.

**FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL
UNIVERSIDADE FEDERAL DE SERGIPE**

T166a Tannus, Danilo Dias
Análise de Wavelet na detecção e diagnóstico de oscilações em
malhas de controle de processo / Danilo Dias Tannus ; orientador
Oscar A. Z. Sotomayor. – São Cristóvão, 2015.
108 f. ; il.

Dissertação (mestrado em Engenharia Elétrica) - Universidade
Federal de Sergipe, 2015.

1. Engenharia elétrica – Matemática. 2. Wavelets (Matemática).
3. Sistemas de energia elétrica – Proteção. 4. Oscilações. I.
Sotomayor, Oscar A. Z., orient. II. Título

CDU 621.317.66

AGRADECIMENTOS

Agradeço à CAPES pelo apoio financeiro, aos meus pais e ao meu orientador, pela dedicação e paciência durante o desenvolvimento desta dissertação.

Agradeço também a Guo Zixu pelas inúmeras consultas via email e a Selvanathan Sivalingam pelo material fornecido.

RESUMO

Uma das principais causas da degradação do desempenho em malhas de controle são as oscilações, as quais têm um efeito negativo sobre o desempenho dessas malhas e pode forçar a planta a operar em condições abaixo do ideal. Um dos passos fundamentais para a avaliação do desempenho de malhas de controle industriais são a detecção e diagnóstico dessas oscilações, motivados também pela crescente ênfase na segurança e capacidade de lucro das instalações. O presente trabalho usa a análise de Wavelet combinada com outras técnicas de análise de sinais, tais como a Função de Autocorrelação e a Causalidade de Granger, para fazer o diagnóstico completo de oscilações em malhas de controle de processos. Testes de simulações numéricas são apresentados para demonstrar a eficácia da metodologia proposta. Primeiramente, as técnicas são utilizadas para o diagnóstico de uma malha de controle simples no formato de controle por modelo interno. Posteriormente, os métodos são aplicados numa unidade de craqueamento catalítico operando sob controle preditivo (MPC). Os resultados obtidos mostram a potencialidade da metodologia proposta para aplicações reais.

Palavras-chave: Degradação do desempenho em malhas de controle, Detecção e diagnóstico de oscilações, Análise de Wavelet, Função de Autocorrelação, Causalidade de Granger

ABSTRACT

One of the main causes of control loop performance degradation are the oscillations, which have a negative effect on the performance of these loops and may force the plant to operate at less than optimal conditions. One of the fundamental steps for the evaluation of industrial control loop performance is the detection and diagnosis of these oscillations, also motivated by the growing emphasis on security and earnings capacity of the installations. This paper uses wavelet analysis combined with other signal analysis techniques such as the autocorrelation function and the Granger Causality, to make the complete diagnosis of oscillations in control loops processes. Numerical test simulations are presented to demonstrate the effectiveness of the proposed method. First, the techniques are used for the diagnosis of a simple control loop in the format of internal model control. After, the methods are applied in a catalytic cracking unit operating under model predictive control (MPC). The results show the potentiality of the proposed methodology to real applications.

Keywords: Control loop performance degradation, Detection and diagnosis of oscillations, Wavelet analysis, Autocorrelation function, Granger Causality

LISTA DE FIGURAS

Figura 2.1: Malha de controle simples implementada em Simulink	30
Figura 2.2: Esquema simplificado da unidade de FCC da REVAP	32
Figura 2.3: Estrutura do controlador MPC	34
Figura 2.4: Implementação do simulador do sistema FCC em Simulink/Matlab™	36
Figura 3.1: Escalonamento da função Wavelet chapéu mexicano	39
Figura 3.2: Deslocamento da função Wavelet chapéu mexicano	40
Figura 3.3: Comparação entre a Wavelet e o início do sinal	41
Figura 3.4: Wavelet deslocada para uma nova comparação com o sinal	41
Figura 3.5: Wavelet escalonada para uma nova comparação com o sinal	41
Figura 3.6: Filtragem do sinal, gerando aproximações e detalhes (Misiti et al., 2008)	43
Figura 3.7: Processo de filtragem do sinal (Misiti et al., 2008)	43
Figura 3.8: Processo de obtenção dos coeficientes de aproximação e detalhe (Misiti et al., 2008)	44
Figura 3.9: Árvore de decomposição Wavelet (Misiti et al., 2008)	44
Figura 3.10: Reconstrução do sinal original a partir da DWT	45
Figura 3.11: Wavelet de Haar	47
Figura 3.12: Ordens da família Daubechies	47
Figura 3.13: Wavelets Biortogonais	49
Figura 3.14: Wavelets de Coiflets	50
Figura 3.15: Família Symlets	50
Figura 3.16: Wavelet chapéu mexicano	51
Figura 3.17: Wavelet Morlet	52

Figura 4.1: Divisão dos métodos para detecção de oscilações em malhas de controle	54
Figura 4.2: Sinal multioscilar e não estacionário da variável de processo	57
Figura 4.3: Variável de processo e sua tendência não estacionária destacada	58
Figura 4.4: PV com sua média deslocada	58
Figura 4.5: Sinal de PV filtrado e com sua média deslocada	59
Figura 4.6: Escalograma da CWT aplicada ao sinal PV	60
Figura 4.7: ACFs dos conteúdos oscilatórios detectados de PV	60
Figura 4.8: Sinais das variáveis controladas y_1 e y_2	62
Figura 4.9: Variáveis controladas e suas tendências não estacionárias destacadas	63
Figura 4.10: Variáveis controladas deslocadas e normalizadas	63
Figura 4.11: Variáveis controladas filtradas	64
Figura 4.12: Escalogramas da CWT aplicada aos sinais filtrados das variáveis controladas y_1 (escalograma à esquerda) e y_2 (escalograma à direita)	64
Figura 4.13: ACFs dos conteúdos oscilatórios detectados das variáveis controladas y_1 e y_2	65
Figura 5.1: Estrutura de controle IMC	69
Figura 5.2: Estrutura IMC implementada no Simulink	71
Figura 5.3: Comportamento do processo, modelo e variável manipulada para o stiction da válvula como fonte de oscilação	72
Figura 5.4: Gráfico da XWT entre mv e yp para o stiction como fonte de oscilação	73
Figura 5.5: Gráfico da XWT entre mv e ym para o stiction como fonte de oscilação	73
Figura 5.6: Comportamento do processo, modelo e saída do controlador para o erro de ganho como causa da oscilação	75

Figura 5.7: Gráfico da XWT entre u e yp para o erro de ganho como causa da oscilação	75
Figura 5.8: Gráfico da XWT entre u e ym para o erro de ganho como causa da oscilação	76
Figura 5.9: Razão da magnitude da XWT entre u e yp e da XWT entre u e ym para o erro de ganho como causa da oscilação	77
Figura 5.10: Diferença de fase da XWT entre u e yp e da XWT entre u e ym para o erro de ganho como causa da oscilação	77
Figura 5.11: Comportamento do processo, modelo e saída do controlador para o erro de atraso como causa da oscilação	78
Figura 5.12: Gráfico da XWT entre u e yp para o erro de atraso como causa da oscilação	79
Figura 5.13: Gráfico da XWT entre u e ym para o erro de atraso como causa da oscilação	79
Figura 5.14: Razão da magnitude da XWT entre u e yp e da XWT entre u e ym para o erro de atraso como causa da oscilação	80
Figura 5.15: Diferença de fase da XWT entre u e yp e da XWT entre u e ym para o erro de atraso como causa da oscilação	81
Figura 5.16: Estimação do período de oscilação de yp para o erro de atraso como causa da oscilação	82
Figura 5.17: Comportamento do processo, modelo e saída do controlador para o erro da constante de tempo como causa da oscilação	84
Figura 5.18: Gráfico da XWT entre u e yp para o erro da constante de tempo como causa da oscilação	84
Figura 5.19: Gráfico da XWT entre u e ym para o erro da constante de tempo como causa da oscilação	85

Figura 5.20: Razão da magnitude da XWT entre u e yp e da XWT entre u e ym para o erro da constante de tempo como causa da oscilação	86
Figura 5.21: Diferença de fase da XWT entre u e yp e da XWT entre u e ym para o erro da constante de tempo como causa da oscilação	86
Figura 5.22: Estimação do período de oscilação de yp para o erro da constante de tempo como causa da oscilação	87
Figura 5.23: Comportamento do processo, modelo e saída do controlador para o erro de ganho e perturbação oscilatória como causas das oscilações	89
Figura 5.24: Gráfico da XWT entre u e yp para o erro de ganho e perturbação oscilatória como causas das oscilações	89
Figura 5.25: Gráfico da XWT entre u e ym para o erro de ganho e perturbação oscilatória como causas das oscilações	90
Figura 5.26: Variáveis manipuladas (mv_1 e mv_2) e variáveis controladas (y_1 e y_2)	97
Figura 5.27: Mapa da causalidade de Granger no domínio do tempo	98
Figura 5.28: Magnitude da causalidade de Granger espectral	99
Figura 5.29: Gráfico da XWT entre mv_2 e y_2 do sistema FCC	100
Figura 5.30: Gráfico da XWT entre mv_2 e ym_2 do sistema FCC	101

LISTA DE TABELAS

Tabela 2.1: Parâmetros de sintonia do controlador MPC	35
Tabela 3.1: Possibilidades de uso das famílias Wavelet	52
Tabela 4.1: Resultados obtidos dos conteúdos oscilatórios de PV	61
Tabela 4.2: Resultados obtidos dos conteúdos oscilatórios das variáveis controladas y_1 e y_2	66

LISTA DE ABREVIACÕES

MV - Variável Manipulada

PV - Variável do Processo

ACF - Autocorrelation Function

WT - Wavelet Transform

PSD - Power Spectral Density

FOPTD - First Order Plus Dead Time

DWT - Discrete Wavelet Transform

CWT - Continuous Wavelet Transform

FFT - Fast Fourier Transform

WPT - Wavelet Packet Transform

IMC - Internal Model Control

FCC - Fluid catalytic cracking

GLP - Gás liquefeito de petróleo

REVAP - Refinaria Vale do Paraíba

PI - Proportional Integral

DCS - Distributed Control System

ODE - Ordinary Differential Equation

LQ - Linear Quadrático

RHC - Receding Horizon Control

QDMC - Quadratic Dynamic Matrix Control

QP - Quadratic_programming

FT - Fourier Transform

STFT - Short Time Fourier Transform

IDWT - Inverse Discrete Wavelet Transform

MIMO - Multiple Input Multiple Output

XWT - Cross Wavelet Transform

GC - Granger Causality

AR - Autoregressive

MVGC - Multivariate Granger Causality

MPC - Model Predictive Control

PCA - Principal Component Analysis

LISTA DE SÍMBOLOS

\hat{y} - valor predito da saída do QDMC

y_{sp} - *setpoint*

k - instante atual de amostragem

p - horizonte de otimização ou de predição do controlador

m - horizonte de controle

T_s - tempo de amostragem

N - horizonte do modelo

u_{\max} - limite máximo das entradas

u_{\min} - limite mínimo das entradas

Δu_{\max} - limite máximo de incremento nas entradas

Q - matriz de ponderação de predições das saídas

R - matriz de fatores de supressão de incrementos nas entradas

Δu - ação de controle

u_1 - entrada da vazão total de ar introduzida no regenerador

u_2 - entrada da abertura da válvula do catalisador regenerado

y_1 - variável controlada da temperatura da fase densa do 1º estágio do regenerador

y_2 - variável controlada da temperatura na saída do *riser*

u_0 - valor no estado estacionário das entradas

y_0 - valor no estado estacionário das saídas

b - fator de deslocamento Wavelet

a - fator de escala Wavelet

W_ψ - Transformada Contínua de Wavelet

ψ - função Wavelet

\bar{T}_P - período médio de oscilação

ΔT_P - variação aleatória no período de oscilação

σ_{T_P} - desvio padrão do período de oscilação

$\sigma_{intervals}$ - desvio padrão dos intervalos de oscilação

r - índice de regularidade

P_i - potência no i -ésimo canal de frequência

A - Aproximação da decomposição DWT

D - detalhe da decomposição DWT

ω_0 - frequência de ajuste da função Wavelet (rad/s)

f_0 - frequência de ajuste da função Wavelet (Hz)

f_{os} - frequência de oscilação

T_o - período de oscilação

W_{xy} - Transformada Cruzada de Wavelet entre duas séries de tempo X e Y

$|W_{xy}|$ - Módulo da Transformada Cruzada de Wavelet entre duas séries de tempo X e Y

\emptyset_{xy} - fase da Transformada Cruzada de Wavelet entre duas séries de tempo X e Y

W_{uyp} - Transformada Cruzada de Wavelet da entrada e saída do processo

W_{uym} - Transformada Cruzada de Wavelet da entrada e saída do modelo

$|W_{uyp}|$ - Módulo da Transformada Cruzada de Wavelet entre a entrada e saída do processo

$|W_{uym}|$ - Módulo da Transformada Cruzada de Wavelet entre a entrada e saída do modelo

ϕ_{uyp} - fase da Transformada Cruzada de Wavelet entre a entrada e saída do processo

ϕ_{uym} - fase da Transformada Cruzada de Wavelet entre a entrada e saída do modelo

$G(s)$ - Função de transferência

yp - saída do processo da malha de controle por modelo interno

ym - saída do modelo da malha de controle por modelo interno

mv - variável manipulada da malha de controle por modelo interno

u - saída do controlador da malha de controle por modelo interno

X_1 - série temporal 1

X_2 - série temporal 2

a - coeficientes autorregressivos

e_i - erro de predição do modelo autorregressivo

$e_{i(j)}$ - erro de predição do modelo autoregressivo que prevê a i -ésima variável pela exclusão da j -ésima variável.

q^{-1} - operador de deslocamento da Causalidade de Granger

σ^2 - variância

$F_{j \rightarrow i}$ - índice da Causalidade de Granger da variável j para a variável i

p_1 - parâmetros do modelo restrito

p_2 - parâmetros do modelo completo

RSS_i - soma dos quadrados dos resíduos no modelo i

no - número total de observações

$S(f)$ - matriz densidade espectral

$I_{2 \rightarrow 1}(f)$ - Causalidade de Granger espectral de X_2 para X_1 na frequência f

mv_1 - variável manipulada da vazão total de ar introduzida no regenerador

mv_2 - variável manipulada da abertura da válvula do catalisador regenerado

ym_2 - saída do modelo da temperatura na saída do *riser*

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO	20
1.1 Preliminares	20
1.2 Objetivos	21
1.3 Motivação	21
1.4 Revisão Bibliográfica	22
1.5 Escopo do Trabalho	28
 CAPÍTULO 2 - ESTUDOS DE CASO	 30
2.1 Introdução	30
2.2 Uma malha de controle simples	30
2.3 Uma Unidade de Craqueamento Catalítico (FCC)	31
2.3.1 Controle da unidade FCC	33
 CAPÍTULO 3 – A TRANSFORMADA DE WAVELET: TEORIA	 37
3.1 Introdução	37
3.2 Transformada Contínua de Wavelet	37
3.2.1 Influência do escalonamento	39
3.2.2 Influência da translação	39
3.2.3 Cinco passos para obter a Transformada Contínua de Wavelet	40
3.3 Transformada Discreta de Wavelet	42
3.3.1 Aproximações e detalhes para estágios de filtragem	42
3.3.2 Reconstrução da Transformada Discreta de Wavelet	44
3.4 Funções Wavelets	45
3.4.1 Haar	46
3.4.2 Daubechies	47
3.4.3 Biortogonal	49
3.4.4 Coiflets	50
3.4.5 Symlets	50
3.4.6 Chapéu Mexicano	51
3.4.7 Morlet	51

CAPÍTULO 4 – APLICAÇÃO DA TRANSFORMADA DE WAVELET NA DETECÇÃO DE OSCILAÇÕES	53
4.1 Introdução	53
4.2 Análise de Wavelet na detecção de oscilações	54
4.3 Aplicação da detecção na malha de controle simples	57
4.4 Aplicação da detecção no sistema FCC	62
 CAPÍTULO 5 – USO DA TRANSFORMADA CRUZADA DE WAVELET E CAUSALIDADE DE GRANGER NO DIAGNÓSTICO DE OSCILAÇÕES	 67
5.1 Introdução	67
5.2 Transformada Cruzada de Wavelet	67
5.3 Análise da diferença de fase	68
5.4 Aplicação da XWT na identificação de oscilações	69
5.5 Aplicação à malha de controle simples	71
5.5.1 Identificação do <i>stiction</i> da válvula	72
5.5.2 Erro planta-modelo	76
5.5.2.1 Erro de ganho	76
5.5.2.2 Erro de atraso	78
5.5.2.3 Erro da constante de tempo	83
5.5.3 Oscilações devido ao erro de ganho e perturbação externa oscilatória	88
5.6 Introdução à Causalidade de Granger	91
5.6.1 Causalidade de Granger no Domínio do Tempo	91
5.6.2 Causalidade de Granger espectral	94
5.7 Aplicação ao sistema FCC	97
5.7.1 Isolamento da oscilação usando a Causalidade de Granger	97
5.7.2 Identificação da oscilação no sistema FCC utilizando a XWT	99
 CAPÍTULO 6 - CONCLUSÕES E RECOMENDAÇÕES	 102
 REFERÊNCIAS BIBLIOGRÁFICAS	 104

Capítulo 1

Introdução

1.1 PRELIMINARES

A crescente demanda por maior desempenho, segurança e confiabilidade dos sistemas industriais tem aumentado a necessidade do diagnóstico de falhas, o qual tem se tornado cada vez mais importante para o monitoramento do processo. Durante as duas últimas décadas, vários sensores foram desenvolvidos e utilizados para o monitoramento de condições e diagnóstico de falhas, entre eles: sensores de deslocamento, vibração, força dinâmica, emissão acústica, temperatura, etc (Bendjama et al., 2012).

Como a maioria das malhas de controle de processos industriais tem preocupações operacionais, os últimos anos testemunharam um rápido desenvolvimento nas pesquisas do monitoramento e avaliação do desempenho dos sistemas de controle. A degradação do desempenho em malhas de controle se manifesta como mau rastreamento do *set point*, oscilações, fraca rejeição das perturbações e excessiva variação do elemento final de controle (Guo et al., 2014).

Vários estudos sobre monitoramento de desempenho mostram que grande parte das malhas de controle na indústria possuem baixo desempenho devido principalmente à má sintonia de controladores, equipamentos defeituosos, não-linearidades nas válvulas de controle causadas por agarramento, estratégias de controle inadequadas e inter-relação entre malhas (Beckman, 1997). As perturbações causadas pelo mau desempenho existentes nas malhas atualmente provêm da transferência de massa e/ou energia entre as diferentes unidades, que se manifestam na maioria das vezes na forma de oscilações que se propagam para outras malhas, dificultando a análise da causa raiz. Em sistemas de cogeração, que têm o propósito de buscar a eficiência energética racionalizando o consumo de combustível para responder às preocupações ambientais, as realimentações existentes colaboram para dificultar a identificação da malha que gerou a oscilação (Rodrigues, 2011).

Estudos apontam que mais de 60% de todos os controladores industriais possuem algum tipo de problema de desempenho. Uma auditoria Canadense mostrou que de todas as malhas de controle analisadas em fábricas de papel e celulose; 30% eram oscilatórias devido aos problemas com válvulas, 30% mal sintonizadas, 20% tinham problemas de projeto e somente 20% tinham comportamento aceitável (Bialkowski, 1993).

A análise de sinais é um dos métodos utilizados mais importantes para monitoramento de condições e diagnóstico de falhas, cujo objetivo é encontrar uma forma simples e eficaz de transformação dos sinais originais. Portanto, as informações importantes contidas nos sinais podem ser exibidas e, em seguida, as características dominantes podem ser extraídas para o diagnóstico (Peng e Chu, 2004).

1.2 OBJETIVOS

O objetivo principal deste trabalho é aplicar a análise de Wavelet combinada com outras técnicas de análise de sinais, tais como Função de Autocorrelação e Causalidade de Granger, para fazer o diagnóstico completo de oscilações em malhas de controle de processos. Primeiramente, as técnicas necessárias são utilizadas para a detecção e diagnóstico de uma malha de controle simples. Posteriormente, os métodos são testados para um sistema industrial, em particular, uma unidade de craqueamento catalítico.

1.3 MOTIVAÇÃO

A maioria das malhas de controle dos processos industriais têm preocupações operacionais. Assim, as pesquisas no monitoramento do desempenho e avaliação do sistema de controle vêm se desenvolvendo cada vez mais nos últimos anos.

Uma das principais causas da degradação do desempenho em malhas de controle são as oscilações, as quais, especialmente múltiplas, causadas principalmente pelo projeto inadequado do sistema de controle e má configuração do processo, perturbações externas, não-linearidade em válvulas de controle, ajuste agressivo do controlador entre outras, têm um efeito negativo sobre o desempenho dessas malhas e pode forçar a planta a operar em condições abaixo do ideal. Nesse sentido, a avaliação do desempenho de malhas de controle industriais tem sido direcionada à detecção e diagnóstico dessas oscilações,

motivados também pela crescente ênfase na segurança das instalações e capacidade de lucro.

A Transformada de Wavelet fornece a possibilidade de análise multirresolução de um sinal, tanto no tempo quanto na frequência. Usa grandes escalas para mostrar as características globais do sinal e pequenas escalas para mostrar os detalhes do mesmo. Com isso, torna-se um método que pode revelar características principais das oscilações, proporcionando uma alternativa para sua detecção e diagnóstico.

1.4 REVISÃO BIBLIOGRÁFICA

As aplicações de métodos para detecção e diagnóstico de oscilações têm recebido atenção significativa nos últimos anos. Porém, o uso da análise de Wavelet para esta finalidade ainda encontra-se em um estágio de desenvolvimento, recebendo destaque nos trabalhos mais atuais. Alguns dos estudos em técnicas de detecção e diagnóstico de oscilações, incluindo o uso da Transformada de Wavelet, são resumidos a seguir:

- Wang (1996) introduziu a Transformada de Wavelet para indicar efeitos de falhas de curta duração em sinais de vibrações. As representações tempo-frequência e tempo-escala foram unificadas em uma forma geral de uma Transformada de Wavelet tridimensional, sendo que as transformações bidimensionais com diferentes vantagens foram tratadas como casos derivados especiais por fixar a variável de escala ou de frequência. A função Wavelet Gaussiana Envelopada foi recomendada para extrair as diferentes características do sinal. Foi mostrado nos exemplos que as distribuições de tempo-frequência e tempo-escala geradas pela Transformada de Wavelet são eficazes na apresentação e análise das características locais dos sinais de vibração de modo que os sistemas mecânicos puderam ser diagnosticados.
- Thornhill e Higglund (1997) introduziram novos critérios para a detecção de oscilações, especialmente aplicável para uma análise *off-line*. A caracterização das oscilações foram apresentadas em termos de um fator de regularidade e um limite que indica as amplitudes relativas do componente oscilatório e sinal de ruído. Introduziram também assinaturas baseadas em harmônicos espectrais e um mapa dinâmico do ponto de ajuste em relação a variável do processo. As rotinas

foram aplicadas a uma malha de controle de refinaria. As análises e as decisões dos procedimentos reforçaram as opiniões dos especialistas do controle de refinaria na maioria dos casos. Os casos de divergência foram totalmente explicados, e o procedimento também deu orientações sobre uma malha com um problema desconhecido.

- Jin e Shi (2001) apresentaram uma metodologia automática para o desenvolvimento de um sistema de diagnóstico utilizando sinais em forma de onda com limitadas informações de falhas. Nessa metodologia, a análise de Wavelet foi usada como ferramenta básica para extrair as características do sinal. Foi escolhida essa ferramenta devido a alguns motivos: sua capacidade de multirresolução, que localiza as propriedades tanto no domínio do tempo quanto na frequência, a rapidez de resolução dos algoritmos para uma implementação *on-line* e sua eficiência na compressão de dados para a extração das características. Como um exemplo real, a análise do sinal de tonelagem destinado a visar o monitoramento do processo foi fornecido para demonstrar a implementação desta metodologia.
- Matsuo et al. (2003) utilizaram uma ferramenta de análise de Wavelet para detecção de oscilações em plantas de indústrias químicas reais, a qual poderia detectar várias oscilações de sinais de medição e mostrar as informações valiosas para o diagnóstico. Para cada uma das oscilações nas malhas de controle detectadas, a causa principal da oscilação seria diagnosticada através da análise das características de entrada e saída de uma válvula. Foi utilizada uma combinação da ferramenta Wavelet e o gráfico variável manipulada (MV) v.s. variável do processo (PV) como um poderoso método para detecção e diagnóstico de oscilações em plantas de processos, em que consideraram, nesse caso, a histerese da válvula como causa da oscilação.
- Thornhill et al. (2003) trataram da detecção das oscilações nas medições de processos químicos, incluindo o caso em que duas ou mais oscilações de frequências diferentes estavam presentes simultaneamente. O procedimento para detecção teve como base os cruzamentos por zero da ACF (Função de Autocorrelação). O benefício do uso da ACF seria a redução dos falsos cruzamentos por zero provocados pelo ruído, pois o ruído aleatório é muito

reduzido na ACF. As oscilações rápidas e lentas foram detectadas de forma independente, mesmo quando estavam presentes simultaneamente.

- Matsuo et al. (2004) fizeram o diagnóstico da principal causa de uma oscilação em uma coluna de destilação que foi atribuída a uma malha de controle de pressão em um estudo de caso na *Mitsui Chemicals*, utilizando uma nova técnica com padrão de resolução de tempo-frequência com a análise de Wavelet como ferramenta. O método identificou as principais características compartilhadas pelas medidas de diferentes lugares na coluna e quantificou as similaridades. Foram detectadas não linearidades na tendência do tempo dos dados de pressão, o que sugeriu inicialmente uma falha no atuador ou sensor como causa principal. Entretanto, o aprofundamento da análise mostrou que a fonte da não linearidade foi a saturação periódica da variável manipulada causada por um ajuste inadequado. O problema foi resolvido pela mudança nas configurações de sintonização do controlador, o que eliminou as perturbações de toda unidade.
- Peng e Chu (2004) apresentaram uma síntese sobre a aplicação de Wavelet no diagnóstico de falhas da máquina, incluindo os seguintes aspectos principais: a análise tempo-frequência dos sinais, a extração das características de falha, a detecção de singularidade nos sinais, a filtragem do ruído e extração dos sinais fracos, a compressão de sinais de vibração e do sistema de identificação. Algumas outras aplicações foram introduzidas bem resumidamente, tais como as redes neurais Wavelet, a função de resposta em frequência baseada em Wavelet, etc. Além disso, os autores fizeram uma análise de trabalhos que trataram de problemas de diagnóstico de falhas da máquina com o uso da análise de Wavelet.
- Matsuo (2005) propôs o estabelecimento de um método genérico para a análise do sistema de controle da planta utilizando análise de Wavelet. Relatou que o comportamento de um processo químico pode ser complicado, e muitas vezes bastante instável. A análise dos dados pode não ser tão simples, uma vez que muitas operações, como a não-linear, dinâmica e elementos interativos são envolvidos no processo. Para a análise desses dados complexos, a Transformada de Wavelet foi introduzida, a qual permitiu a abstração de padrões dos dados do processo e tornou mais fácil a análise desses dados. Foi verificado também o

mérito de usar a WT, em comparação com o método clássico de Fourier, na análise de processos químicos.

- Srinivasan et al. (2005) propuseram um novo método para diagnóstico e estimativa de *stiction*. O sucesso do trabalho se deu por uma técnica inédita de detecção e caracterização do tempo de oscilações. O algoritmo de caracterização das oscilações, em vez de apenas fazer a detecção a partir dos dados industriais, também identificaria os cruzamentos por zero dos dados. Isso permitia a extração dos ciclos individuais das oscilações e um eficiente tratamento dos sinais que eram não constantes e não lineares. Foi proposto um método robusto para a geração de um modelo padrão de atrito estático para cada ciclo de oscilação, em oposição a um padrão global de todo o conjunto de dados. O algoritmo *Dynamic Time Warping* da configuração padrão dos dados reais em cada ciclo de oscilação foi usado para a classificação dos testes padrões, o qual funcionaria de forma eficiente nas características padrões triangulares, senoidais, retangulares e trapezoidais. A abordagem proposta foi testada em dados de complexidade variável, como em oscilações não constantes, *stiction* intermitente e perturbações externas. Em alguns casos o método poderia falhar, caso outras falhas, além do atrito estático, afetassem o ciclo simultaneamente, o que mudaria as formas dos padrões. Nos casos em que as oscilações não fossem diagnosticadas como *stiction*, uma análise mais aprofundada para identificar a causa seria necessária.
- Thornhill e Horch (2007) analisaram os avanços na detecção e diagnóstico de perturbações nos sistemas de controle de plantas de processos químicos e discutiram novos rumos que tenderiam a ser promissores para o futuro. As principais causas de perturbações na planta são ciclo-limites não lineares, interações do controlador e problemas de ajuste. O diagnóstico de não-linearidades, especialmente devido ao *stiction* da válvula, tem sido uma área bem atuante. Detecção de interações do controlador e perturbações devido à estrutura da planta são questões que permanecem em estudo, e precisaria de novas abordagens. Por fim, recomendaram que a ligação da análise dos dados com um modelo qualitativo do processo teria uma boa perspectiva, ou seja, a vinculação das informações do *layout* da planta com a análise do sinal.

- Karra e Karim (2009) desenvolveram uma nova tecnologia para preencher algumas lacunas no diagnóstico de oscilações, como diagnósticos errados ou indecisos para algumas regiões da dinâmica do processo, falhas no caso de múltiplas falhas quando ocorrem simultaneamente e ausência da quantificação da causa. A técnica foi baseada na Densidade Espectral de Potência (PSD) e Função de Auto Correlação (ACF) baseada no método de detecção de oscilações seguidos por um modelo baseado na abordagem de identificação e quantificação da causa das oscilações. A metodologia foi validada em estudos de caso industriais e de simulação para vários casos de *stiction*, má sintonização do controlador e perturbações externas. Esta foi validada com sucesso em sistemas FOPTD (*First Order Plus Dead Time*) e sistemas de integração com uma larga faixa de parâmetros dinâmicos, em que foi demonstrado que não havia áreas cinzentas (regiões indecisas) nem áreas pretas (diagnósticos errados) no diagnóstico de oscilações. Estendendo esse método para o caso de múltiplas entradas e múltiplas saídas, o algoritmo necessitaria de mais eficiência na otimização para identificar o modelo descontínuo de Hammerstein, o qual ainda seria desenvolvido.
- Zhanyang et al. (2009) apresentaram um novo método não-invasivo de detecção de *stiction* na válvula utilizando tecnologia Wavelet. A ideia principal foi usar a decomposição Wavelet para detectar possíveis padrões de *stiction* em múltiplas escalas de resolução. Um método Wavelet adaptativo para tirar o ruído foi aplicado aos dados, preservando as características de atrito estático da válvula durante a remoção deste ruído. Estas características foram extraídas e o índice de atrito estático da válvula calculado. O método funcionou bem e está sendo aplicado a dados industriais reais.
- Selvanathan e Morten (2011) abordaram a detecção e diagnóstico de oscilações devido a múltiplas fontes, em uma estrutura de modelo interno de controle. A abordagem foi baseada na Transformada Cruzada de Wavelet para identificar as fontes das oscilações nas malhas de controle, através da exploração das informações de fase do domínio Wavelet entre os sinais de entrada e saída. O método foi aplicado a uma estrutura de modelo interno de controle com diferentes fontes de oscilações: *stiction* da válvula, erro do modelo da planta (erro de ganho, erro da constante de tempo e erro de atraso) e perturbações externas oscilatórias.

- Bendjama et al. (2012) utilizaram a Transformada de Wavelet para analisar sinais de vibração afim de melhorar as condições de monitoramento e diagnóstico de falhas de máquinas rotativas. A WT (Transformada de Wavelet) é um dos métodos mais importantes para processamento de sinais e é especialmente adequado para a medição de vibrações não estacionárias obtidas a partir de acelerômetros. DWT (Transformada Discreta de Wavelet) e CWT (Transformada Contínua de Wavelet) foram testadas em sinais reais de medição coletados a partir de um sistema de vibração contendo desequilíbrio de massa e falha na engrenagem. Os resultados do monitoramento indicam que o WT pode diagnosticar a alteração anormal nos dados medidos.
- Costa et al. (2012) utilizaram a Transformada Discreta de Wavelet para fazer o pré-processamento dos sinais de vibração com o objetivo de remover o ruído e preservar as principais características do sinal que permitiriam o diagnóstico de falha. O trabalho apresentou algumas aplicações da Transformada de Wavelet na área de diagnóstico de falhas em caixas de engrenagens e apresentou a potencialidade do uso da técnica de remoção de ruído combinadas com técnicas padrão de diagnóstico de falhas como o FFT. Como exemplo, foi simulado e analisado um sinal típico de falha de caixa de engrenagem operando com excentricidade. Verificou-se que essa técnica seria uma ferramenta importante no pré-processamento de sinais ruidosos, realçando o sinal a ser analisado.
- Delvecchio (2012) teve como objetivo avaliar a eficácia das técnicas CWT e DWT para o monitoramento das condições de máquinas. Neste estudo, WTs foram utilizadas especificamente para sinais de vibração capturados a partir de estudos complexos de casos que eram pouco tratados na literatura: acoplamentos marinhos e motores i.c. testados em condições de frio. Aplicaram-se tanto a CWT quanto a DWT. A primeira foi utilizada para a identificação de falhas e caracterização do evento impulso através da análise de uma representação tridimensional dos coeficientes CWT. A última foi aplicada para fins de filtragem e extração de características e para a detecção de eventos impulsivos que foram fortemente mascarados pelo ruído. A tradicional CWT do sinal residual (ou seja, o sinal obtido subtraindo-se a média de tempo síncrona do sinal bruto) com a Wavelet mãe Morlet revelou-se como a ferramenta mais poderosa em localizar a falha de montagem dentro da cinemática do motor. Pôde-se concluir que a aplicação das

WTs não só permitiu que as alterações no estado do equipamento testado pudessem ser reconhecidos, mas também a localização da fonte das alterações.

- Guo, Shen, et al. (2014) propuseram um método automático baseado na análise de Wavelet para detectar múltiplas oscilações em malhas de controle. A redundância da representação pôde ser explorada para indicar com precisão a localização de comportamentos oscilatórios no plano tempo-frequência. Componentes oscilatórios foram separados pelo projeto de adaptação do banco filtro. O método é aplicável a dados não estacionários e ruidosos, devido à análise multirresolução das Wavelets bases ortonormais. O artigo termina com demonstrações eficazes do método proposto utilizando dados industriais como referência.
- Guo, Xie, et al. (2014) implementaram uma técnica de detecção automática de múltiplas oscilações não estacionárias em malhas de controle industriais. A técnica foi baseada na melhoria da WPT (*Wavelet Packet Transform*). Foi obtida uma resolução de frequência ideal dos dados do processo para fins de detecção das oscilações em forma de uma árvore binária. Exemplos de simulação e a implementação em dados industriais verificaram a aplicabilidade da técnica proposta. Essas aplicações em cenários comuns de oscilação ilustraram as vantagens da abordagem proposta em relação às técnicas tradicionais.
- Yuan e Qin (2014) apresentaram um novo método para diagnosticar as fontes e caminhos de propagação das oscilações em processos industriais. O método proposto seleciona as variáveis características que carregam oscilações comuns significantes, em seguida aplica a Causalidade de Granger no domínio do tempo e o espectro da Causalidade de Granger para fornecer um diagnóstico confiável das fontes de oscilação. A técnica não exige modelos do processo nem das perturbações e foi aplicado em dois estudos de caso, mostrando-se promissor para o diagnóstico da causa principal de oscilações em plantas industriais.

1.5 ESCOPO DO TRABALHO

A presente dissertação está composta pelos seguintes capítulos:

No capítulo 1, apresentam-se os objetivos do trabalho, assim como a motivação e uma revisão bibliográfica de alguns trabalhos relacionados encontrados na literatura.

O capítulo 2 detalha os estudos de caso, uma malha de controle simples e uma unidade de craqueamento catalítico operando com controle avançado, que são plataformas de simulação em que serão testadas todas as técnicas de detecção e diagnóstico de oscilações a serem desenvolvidas neste trabalho.

O capítulo 3 apresenta a teoria das Transformadas contínua e discreta de Wavelet, que será a base para o entendimento das técnicas que serão usadas posteriormente.

O capítulo 4 mostra a aplicação da detecção de oscilações nos estudos de caso apresentados no capítulo 2. Nesta fase de detecção, Wavelet é combinada com a Função de Autocorrelação (ACF) para obter um resultado mais eficiente.

No capítulo 5 é apresentada a teoria da Transformada Cruzada de Wavelet, técnica utilizada para a identificação da fonte das oscilações, e a Causalidade de Granger, método utilizado para o isolamento do canal entrada-saída de maior incidência da perturbação, no caso da unidade de craqueamento catalítico, por ser este um sistema de controle com múltiplas entradas e múltiplas saídas.

No capítulo 6 conclui-se o trabalho, incluindo algumas ideias para trabalhos futuros.

Capítulo 2

Estudos de Caso

2.1 INTRODUÇÃO

Neste capítulo são apresentados os processos simulados nos quais serão realizados os testes para detecção e diagnóstico de oscilações. O primeiro, uma malha de controle simples proposta na literatura, e o segundo, uma unidade de craqueamento catalítico (FCC) sob controle avançado, a qual representa um processo mais complexo e realístico.

2.2 UMA MALHA DE CONTROLE SIMPLES

Este primeiro modelo representa uma malha de controle simples e foi implementado no pacote Simulink/Matlab™ (The Mathworks, Inc., 2010). É composto por um controlador PI (proporcional-integrativo), um bloco que simula uma não-linearidade, neste caso o *stiction* na válvula de controle baseado no modelo de Choudhury (2005a), uma perturbação externa oscilatória e ruído gaussiano, com média zero e variância um, adicionados à saída de um processo, o qual está definido por uma função de transferência de 4ª ordem (Figura 2.1).

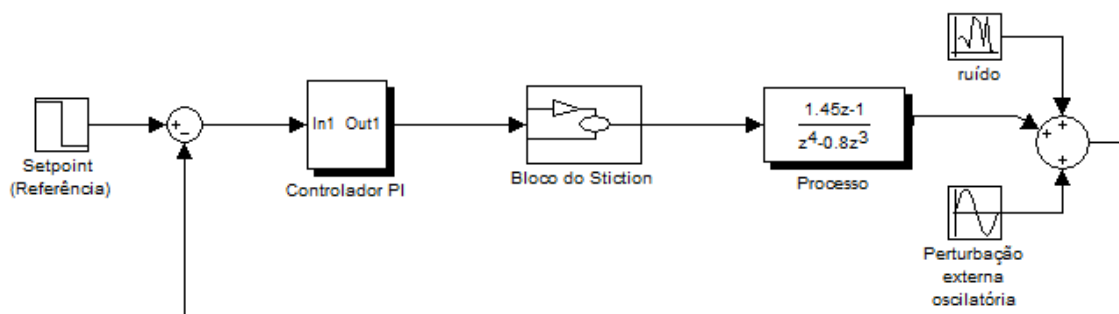


Figura 2.1: Malha de controle simples implementada em Simulink/Matlab™

2.3 UMA UNIDADE DE CRAQUEAMENTO CATALÍTICO (FCC)

Um diagrama simplificado da unidade de craqueamento catalítico (FCC) Kellog modelo F, similar à usada atualmente na Refinaria Vale do Paraíba (REVAP) de São José dos Campos-SP, é apresentado na Figura 2.2. A unidade é alimentada por duas correntes: gasóleo, proveniente de tanque, e óleo desasfaltado, o qual vem diretamente da unidade de desasfaltação a propano e contém um alto teor de hidrocarbonetos pesados. Estas correntes se juntam e a mistura, após aquecimento no forno, é enviada para o *riser* junto com o catalisador proveniente do regenerador, provocando as reações endotérmicas de craqueamento catalítico. Os produtos da reação e o catalisador deixam o *riser* e entram no reator. Nesta secção o catalisador é separado da fase gasosa que contém os hidrocarbonetos, os quais são conduzidos à etapa de recuperação na fracionadora principal. Durante as reações de craqueamento ocorre a deposição de coque na superfície do catalisador, a qual afeta o rendimento da reação. Assim, o catalisador precisa ser reativado, fato que ocorre no regenerador através da combustão de coque com ar proveniente do soprador. O regenerador é dividido em duas partes principais denominadas 1º e 2º estágios de regeneração. Cada um dos estágios é composto por uma fase densa formada por um leito fluidizado de catalisador e, sobre a mesma, uma fase diluída formada pelos gases de combustão proveniente da queima do coque e catalisador arrastado da fase densa. O catalisador que vem do reator é depositado na fase densa do 1º estágio o qual transborda sobre um vertedouro para o 2º estágio onde é concluído o processo de reativação. Acima das fases diluídas do 1º e 2º estágios forma-se uma região denominada fase diluída geral, da qual os gases de combustão são usados na geração de vapor na caldeira de CO.

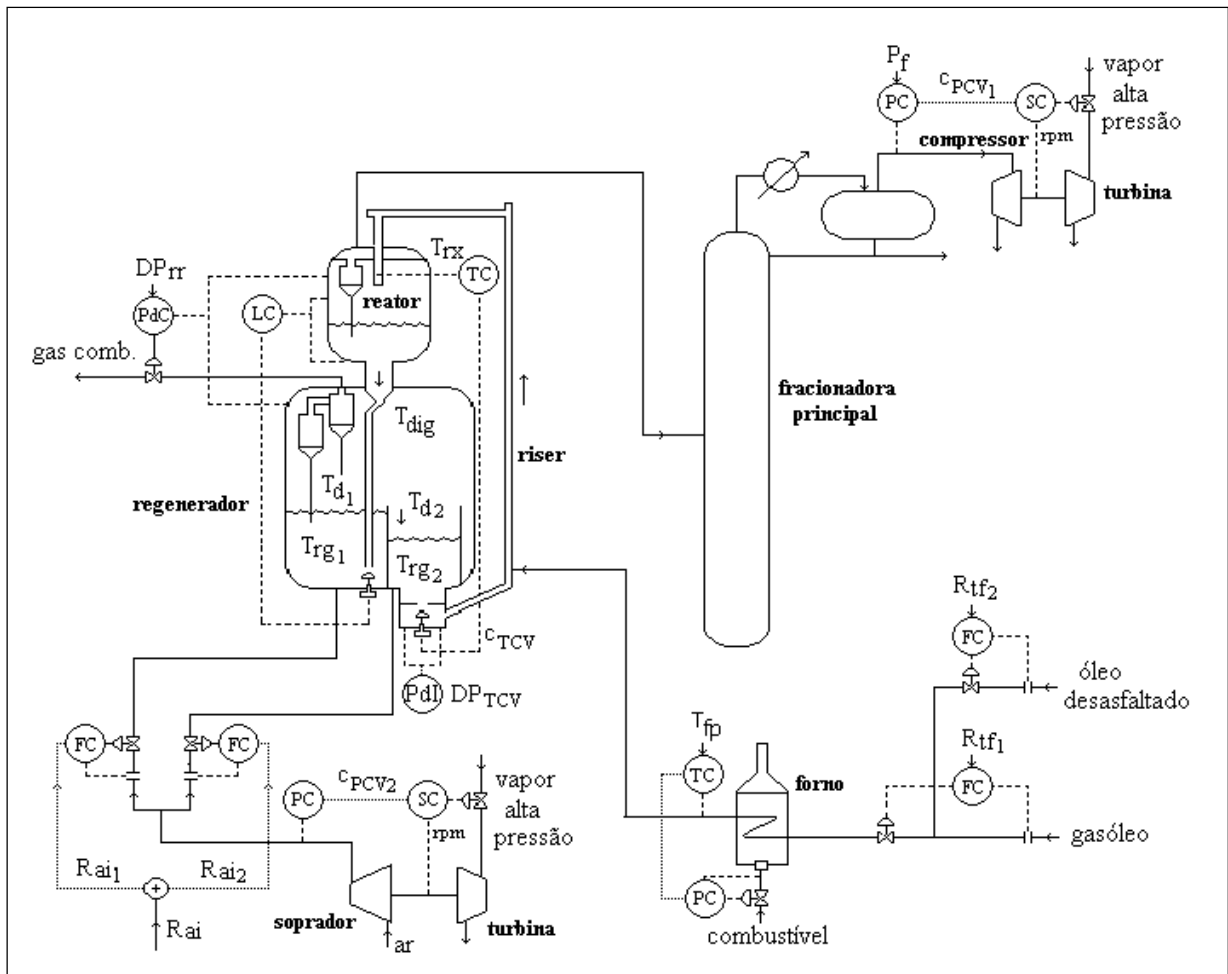


Figura 2.2: Esquema simplificado da unidade de FCC da REVAP

O processo pode ser simulado com o modelo fenomenológico provido por Moro e Odloak (1995), o qual foi validado com dados industriais provenientes da REVAP. Este modelo, constituído por 26 ODEs e 74 equações algébricas lineares e não-lineares, escrito em linguagem C e implementado na plataforma Simulink/Matlab™, vem sendo usado para avaliação de novas estruturas de controle de FCC na PETROBRAS (Zanin et al., 2002). No presente trabalho, as equações do modelo e os parâmetros do processo serão omitidos, porém podem ser encontrados na referência acima mencionada.

Para a operação estável do FCC, o simulador inclui, necessariamente, controladores convencionais PI para controlar a pressão diferencial entre o reator e o regenerador, o nível de catalisador no reator e a pressão de sucção do compressor. Estes controladores são implementados internamente no sistema de controle distribuído (DCS).

2.3.1 CONTROLE DA UNIDADE FCC

A operação da unidade de FCC é extremamente complexa. Existem várias restrições operacionais que devem ser mantidas dentro de certos limites mínimos e máximos. O desempenho do sistema depende altamente da estrutura de controle selecionada. O controle da unidade de FCC é por definição um problema multivariável ao invés de um problema multi-malha e, portanto, o Controle Preditivo ou MPC (*Model Predictive Control*) tende a ser a melhor escolha para este propósito.

O MPC se refere a uma classe de algoritmos de controle automático que controla a resposta futura da planta através do uso de um modelo explícito do processo. Em cada instante de amostragem, o MPC soluciona *on-line* um problema linear quadrático (LQ), usando o estado atual da planta como estado inicial. O resultado da otimização gera uma sequência de controle ótimo em malha aberta que é aplicada de acordo com a filosofia de controle de horizonte móvel (*Receding Horizon Control*, RHC), onde só a primeira ação de controle desta sequência é usada, fornecendo um controlador com as características de realimentação desejadas.

No presente caso, a unidade FCC opera sob um esquema MPC, baseado no algoritmo QDMC (*Quadratic Dynamic Matrix Control*) de García e Morshedi (1986), que usa um modelo de convolução discreta (modelo de resposta ao degrau ou de resposta ao impulso do processo) para predição, é amplamente usado na indústria de processos (Qin e Badgwell, 2003).

Basicamente, o QDMC calcula os valores das variáveis manipuladas (ações de controle) que minimizam a diferença entre os valores preditos e desejados das variáveis controladas, sujeitas a restrições nas variáveis manipuladas. Em geral, o algoritmo QDMC minimiza um funcional de custo LQ da seguinte forma:

$$\min_{\Delta u} \sum_{i=1}^p \left(\hat{y}(k+i) - y_{sp} \right)^T Q \left(\hat{y}(k+i) - y_{sp} \right) + \sum_{j=1}^m \Delta u(k+j-1)^T R \Delta u(k+j-1) \quad (2.1)$$

sujeito a:

$$\begin{aligned}
-\Delta u_{\max} &\leq \Delta u(k+j-1) \leq \Delta u_{\max}, \quad j=1, \dots, m \\
u_{\min} &\leq u(k-1) + \sum_{i=1}^j \Delta u(k+i-1) \leq u_{\max}, \quad j=1, \dots, m
\end{aligned} \tag{2.2}$$

em que $\hat{y}(k+i)$ é o valor predito da saída, y_{sp} é o setpoint, $\Delta u(k+i-1) = u(k+i-1) - u(k+i-2)$ é o incremento nas entradas, k é o instante atual de amostragem, p é o horizonte de otimização ou de predição do controlador, m é o horizonte de controle, u_{\max} e u_{\min} são os limites máximos e mínimos das entradas, Δu_{\max} é o limite máximo de incremento nas entradas, Q e R são matrizes diagonais de ponderação positiva definida e positiva semidefinida, respectivamente.

O problema de otimização (2.1) sujeito às restrições (2.2) é resolvido usando programação quadrática (QP). Nota-se que só a primeira ação de controle do vetor Δu é aplicado na planta. Um diagrama esquemático da estrutura do controlador MPC é mostrado na Figura 2.3.

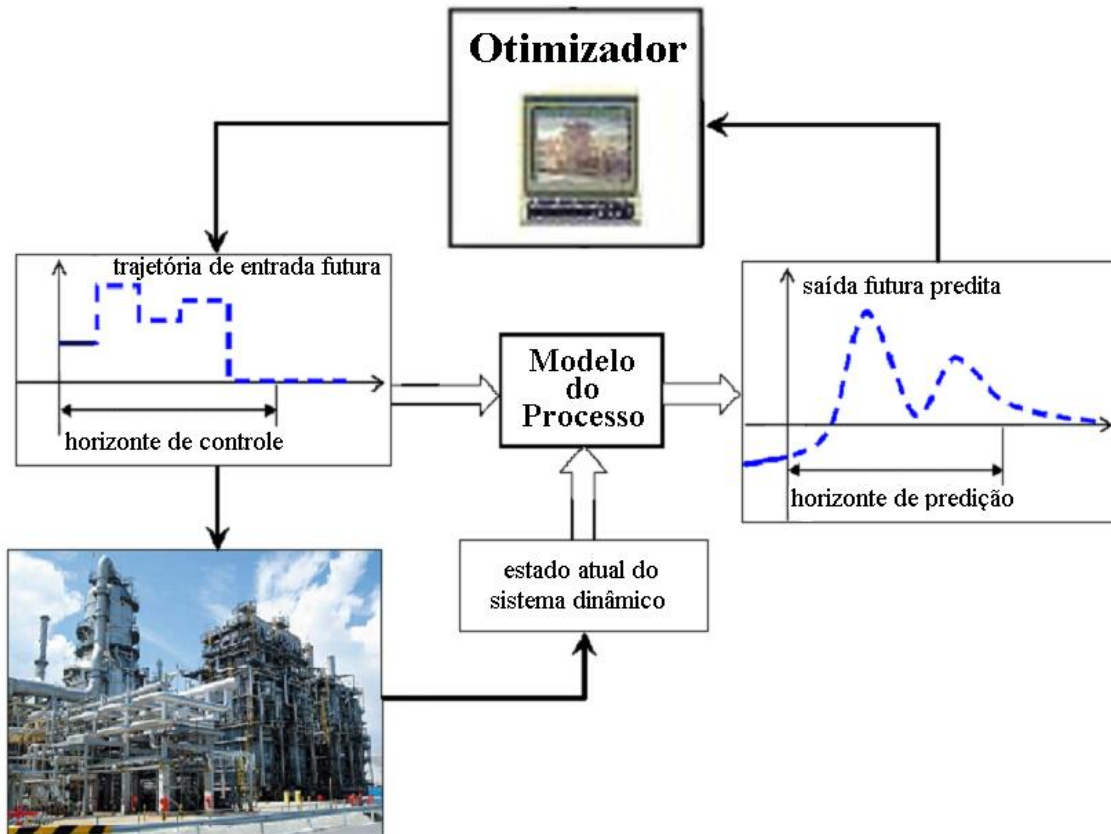


Figura 2.3: Estrutura do controlador MPC

A estrutura de controle do FCC é um parte da versão original da estrutura de controle usado na REVAP. Deste esquema, e para efeitos deste estudo, só será considerado um subsistema 2x2 onde as entradas manipuladas u_1 e u_2 são a vazão total de ar introduzida no regenerador (ton/h) e abertura da válvula de catalisador regenerado (%), respectivamente, e as saídas controladas y_1 e y_2 são a temperatura da fase densa do 1º estágio do regenerador (°C) e a temperatura na saída do *riser* (°C), respectivamente.

O modelo linear do processo usado no controlador, obtido através da resposta ao degrau, é representado pela seguinte matriz de funções de transferência:

$$G(s) = \begin{bmatrix} \frac{0,05849s + 0,001511}{s^2 + 0,04098s + 0,001637} & \frac{-3,286s - 0,02789}{s^2 + 0,02584s + 0,0008785} \\ \frac{0,0192s + 0,0006117}{s^2 + 0,03753s + 0,001128} & \frac{-0,0002252s + 0,0001218}{s^2 + 5907s + 150,1} \end{bmatrix} \quad (2.3)$$

A implementação do controlador MPC considera os parâmetros de sintonia conforme listados na Tabela 2.1.

Tabela 2.1: Parâmetros de sintonia do controlador MPC

Parâmetro	Descrição	Valor
T_s	Tempo de amostragem	1 min
N	Horizonte do modelo	75
p	Horizonte de predição	10
m	Horizonte de controle	2
Δu_{\max}	Limite max. de incremento nas entradas	$[1 \ 0,015]^T$
u_{\max}	Limite máximo das entradas	$[240 \ 0,95]^T$
u_{\min}	Limite mínimo das entradas	$[210 \ 0,45]^T$
Q	Matriz de ponderação de predições das saídas	$\text{diag}([1 \ 1])$
R	Matriz de fatores de supressão de incrementos nas entradas	$\text{diag}([5 \ 5])$

Os valores no estado estacionário das entradas manipuladas e saídas controladas são $u_0 = [221 \ 0,82]^T$ e $y_0 = [670,14 \ 542,2]^T$, respectivamente. A Figura 2.4 mostra a implementação do simulador do sistema controlado na plataforma Simulink/MATLAB™.

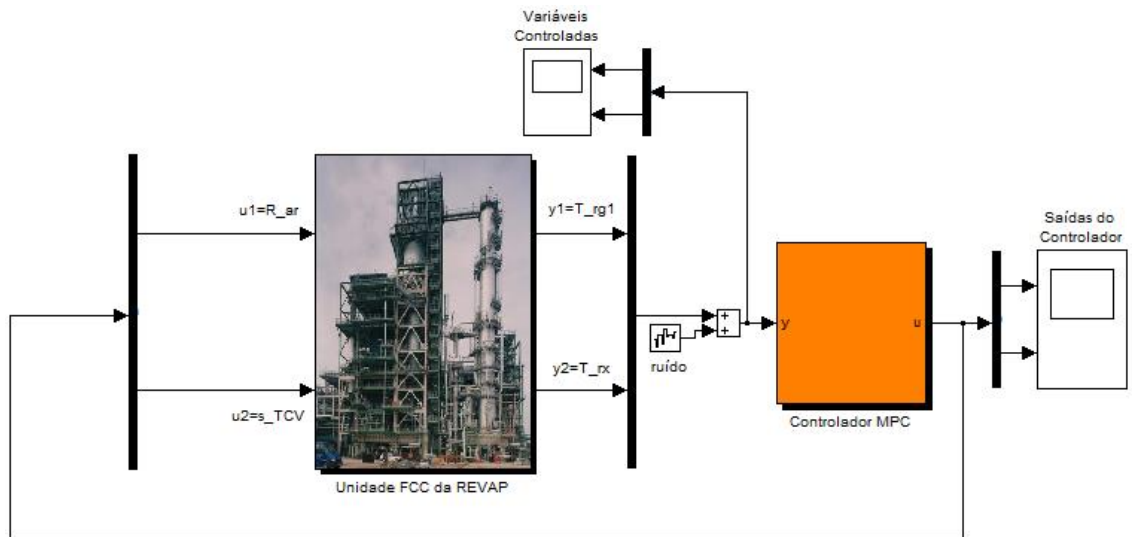


Figura 2.4: Implementação do simulador do sistema FCC em Simulink/Matlab™

Capítulo 3

A Transformada de Wavelet: Teoria

3.1 INTRODUÇÃO

Com o rápido desenvolvimento das técnicas de processamento de sinal, a análise dos sinais estacionários tem sido baseada em técnicas espectrais bem conhecidas, tais como: Transformada de Fourier (FT), Transformada Rápida de Fourier (FFT) e Transformada de Fourier de Tempo Curto (STFT). Infelizmente, os métodos baseados em Fourier não são adequados para a análise de sinais não-estacionários, pois eles não são capazes de revelar as informações inerentes desses tipos de sinais. Esses métodos fornecem apenas um desempenho limitado para o diagnóstico. A fim de resolver estes problemas, a Transformada de Wavelet (WT) foi desenvolvida. A WT é um tipo de técnica de janela variável, que utiliza um intervalo de tempo para analisar os componentes de alta frequência e de baixa frequência do sinal. Os dados utilizados pela WT podem ser decompostos em coeficientes de aproximações e detalhes em um ambiente multiescalar, tornando-se uma ferramenta eficaz para a análise de sinais não-estacionários. Muitos estudos apresentam as aplicações da WT para decompor os sinais, a fim de melhorar o desempenho na detecção e diagnóstico de falhas (Bendjama et al., 2012).

3.2 TRANSFORMADA CONTÍNUA DE WAVELET

A Transformada Contínua de Wavelet (CWT) é definida como uma integral de todo o sinal multiplicado por versões deslocadas, tal deslocamento representado por b , e escalonadas, representadas por a , da função Wavelet mãe, da forma (Huang e Su, 2007):

$$W_{\psi}(a, b) = \int_{-\infty}^{\infty} f(t) \psi_{*a,b}(t) dt \quad (3.1)$$

sendo que * denota o complexo conjugado. Esta também pode ser definida pelo produto interno entre o sinal e as funções Wavelet:

$$W_{\psi}(a, b) = \langle f(t), \psi_{a,b}(t) \rangle \quad (3.2)$$

Os resultados da CWT são muitos coeficientes C em função da escala e posição. Esses coeficientes são ditas correlações cruzadas do sinal com as funções Wavelets.

A função Wavelet $\psi_{a,b}(t)$ é obtida através de uma função $\psi(t)$ pela seguinte transformação:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (3.3)$$

Fazendo a substituição da função Wavelet obtém-se:

$$W_{\psi}(a, b) = \frac{1}{\sqrt{a}} \langle f(t), \psi_{a,b}(t) \rangle = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \cdot \psi\left(\frac{t-b}{a}\right) dt \quad (3.4)$$

A função Wavelet mãe deve satisfazer a seguinte condição:

$$C_{\psi} = \int_{-\infty}^{\infty} \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < \infty \quad (3.5)$$

sendo que “||” representa a magnitude e $\hat{\psi}(\omega)$ é a Transformada de Fourier de $\psi(t)$.

O inverso da Transformada Contínua de Wavelet é dado por

$$f(t) = \frac{1}{c_{\psi}} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} W_{\psi} f(a, b) \psi_{a,b}(t) \frac{1}{a^2} da db \quad (3.6)$$

Como a análise de Wavelet produz uma visão de tempo-escala do sinal, é importante detalhar o que seria esse escalonamento e deslocamento do sinal.

3.2.1 INFLUÊNCIA DO ESCALONAMENTO

Escalonamento de uma função Wavelet significa somente alongá-la ou comprimí-la. Desta forma, quanto maior o fator de escala a , mais longa será a função e maior a parte do sinal a ser comparado, portanto mais superficiais serão as medidas do sinal feitas pelo coeficiente Wavelet. Quanto menor o fator de escala, mais comprimida será a função. O efeito do fator de escala pode ser observado na Figura 3.1.




Figura 3.1: Escalonamento da função Wavelet chapéu mexicano

3.2.2 INFLUÊNCIA DA TRANSLAÇÃO

O deslocamento ou translação de uma função Wavelet significa simplesmente atrasar ou adiantar o seu surgimento. Matematicamente, o atraso de uma função $f(t)$ por b é representado por $f(t - b)$.




Figura 3.2: Deslocamento da função Wavelet chapéu mexicano

3.2.3 CINCO PASSOS PARA OBTER A TRANSFORMADA CONTÍNUA DE WAVELET

A Transformada Contínua de Wavelet é a soma de todo o sinal no intervalo do tempo multiplicado por versões escalonadas e deslocadas da função Wavelet. Este processo produz coeficientes Wavelet que são em função da dimensão e posição.

É um processo relativamente simples. A seguir estão os cinco passos de um procedimento prático para criar uma CWT (Misiti et al., 2008):

- 1) Selecionar uma Wavelet e comparar a uma seção no início do sinal original.
- 2) Calcular o coeficiente C , que representa a relação entre a função Wavelet e a seção do sinal onde está ocorrendo a comparação. Quanto maior o C , maior a semelhança. O resultado dependerá totalmente da Wavelet escolhida.




Figura 3.3: Comparação entre a Wavelet e o início do sinal

- 3) Deslocar a Wavelet para a direita e repetir o passo 2, até que todo o sinal seja coberto.




Figura 3.4: Wavelet deslocada para uma nova comparação com o sinal

- 4) Escalonar a Wavelet e repetir os passos 2 e 3.




Figura 3.5: Wavelet escalonada para uma nova comparação com o sinal

- 5) Repetir os passos de 2 a 4 para todos os valores de escala.

3.3 TRANSFORMADA DISCRETA DE WAVELET

Uma enorme quantidade de dados é gerada quando é feito o cálculo dos coeficientes Wavelet em todas as escalas possíveis. A Transformada discreta de Wavelet usa escalas e posições baseadas em potências de dois, também chamadas de diáticas. A análise foi desenvolvida por Mallat em 1988.

Como na análise discreta o escalonamento e deslocamento ocorrem em intervalos discretos, e não contínuos, uma pequena mudança é efetuada na Wavelet contínua, gerando a seguinte equação:

$$\psi_{m,n}(t) = a_0^{-0.5m} \psi(a_0^{-m}t - nb_0) \quad (3.7)$$

Desta forma, a Transformada discreta de Wavelet é dada por:

$$\langle f, \psi_{a,t} \rangle = a_0^{-0.5m} \int f(t) \psi(a_0^{-m}t - nb_0) dt \quad (3.8)$$

Na equação, m é o inteiro relacionado com as variações da escala e n é o inteiro associado às variações do deslocamento. Os termos a_0 e b_0 são fixos. O primeiro é o parâmetro de dilatação, relacionado a escala e $a_0 > 1$, e o segundo é o fator de translação, relacionado com o deslocamento, dependente de $\psi(t)$ e $b_0 > 0$.

3.3.1 APROXIMAÇÕES E DETALHES PARA ESTÁGIOS DE FILTRAGEM

O princípio da DWT parte da ideia de dividir o sinal a ser analisado em aproximações e detalhes. As aproximações são componentes de alta escala, ou de baixa frequência da série, e os detalhes são componentes de baixa escala ou alta frequência. Portanto, o sinal original passa por um processo de filtragem, correspondente a um filtro passa-baixa e um passa-alta, os quais geram dois sinais (Figura 3.6). Porém, este processo teria dois sinais resultantes, cada um com o mesmo número de amostras no sinal original, ou seja, o processo geraria o dobro de amostras (Figura 3.7).




Figura 3.6: Filtragem do sinal, gerando aproximações e detalhes (Misiti et al., 2008)

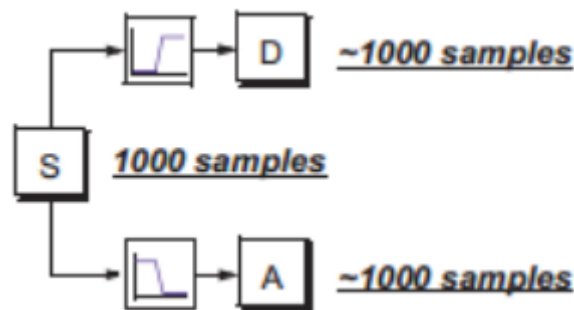


Figura 3.7: Processo de filtragem do sinal (Misiti et al., 2008)

Para evitar este aumento de dados, a decomposição na DWT é feita reduzindo-se a taxa ou variação de amostragem proporcionalmente ao número de decomposições, ou seja, é feito um processo de subamostragem que irá produzir duas sequências de coeficientes (os coeficientes de aproximações e coeficientes de detalhes) cada um destes com metade das amostras do sinal filtrado, como pode ser visto na Figura 3.8. Desta forma, o processo de decomposição atua sempre sobre os componentes da aproximação e tem uma diminuição da resolução. Portanto, cada filtragem efetuada origina um nível de decomposição, sendo a primeira feita sobre o sinal original e as posteriores em relação às suas aproximações obtidas. Este processo é chamado de árvore de decomposição Wavelet. (Figura 3.9).

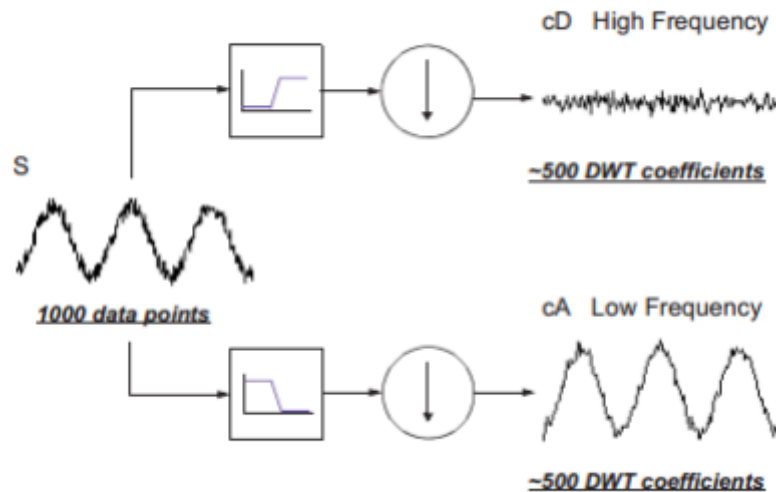


Figura 3.8: Processo de obtenção dos coeficientes de aproximação e detalhe (Misiti et al., 2008)




Figura 3.9: Árvore de decomposição Wavelet (Misiti et al., 2008)

O limite de níveis da decomposição ocorre quando os detalhes individuais consistirem de uma única amostra. Na prática isso é feito selecionando um número apropriado de níveis de acordo com a natureza do sinal, o qual apresenta um determinado nível de entropia.

3.3.2 RECONSTRUÇÃO DA TRANSFORMADA DISCRETA DE WAVELET

A partir das aproximações e detalhes do processo de decomposição é possível reconstruir um determinado sinal original. Este processo de reconstrução é a Transformada Discreta de Wavelet Inversa (IDWT).

Para ser feita a reconstrução do sinal, no caso da DWT de uma decomposição, soma-se a aproximação e o detalhe gerado pela transformada, e esta soma será o sinal original. Já em um processo de decomposição multinível que segue a árvore de decomposição da DWT, para reconstruir o sinal, soma-se a última aproximação gerada com todos os detalhes gerados, e esta soma será o sinal original. Este processo é mostrado na Figura 3.10 (Misiti et al., 2008):

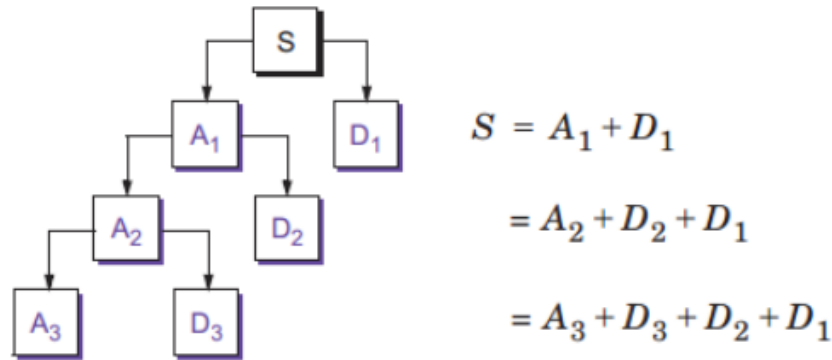


Figura 3.10: Reconstrução do sinal original a partir da DWT

3.4 FUNÇÕES WAVELETS

Existem muitas funções base, e cada uma delas identifica uma família de Wavelets. Para uma escolha adequada de uma função Wavelet, deve-se levar em conta alguns critérios, como se a função é ou não ortogonal, se é real ou complexa, levar em consideração também o seu formato, suavidade, etc.

- Suavidade - A suavidade de uma Wavelet pode ser determinada pelo número de momentos nulos de ψ . Uma Wavelet tem p momentos nulos se (Negri, 2012):

$$\int_{-\infty}^{\infty} x^k \psi(x) dx = 0, \quad \text{para todo} \quad 0 \leq k < p \quad (3.9)$$

- Ortogonalidade - Para Wavelets ortogonais, na transformada, o número de convoluções em cada escala é proporcional à janela da função Wavelet escolhida nesta escala. A Transformada de Wavelet obtida utilizando-se famílias de Wavelets não ortogonais é altamente redundante em escalas maiores, nas quais o

Espectro Wavelet em tempos adjacentes é altamente correlacionado. A WT não ortogonal é útil na análise de séries temporais (válido também para séries espaciais) nas quais atenuações e variações contínuas na amplitude Wavelet são esperadas (Protázio, 2002).

- Real ou complexa - Uma função Wavelet real fornece apenas informação sobre uma componente e pode ser utilizada apenas para localizar picos e descontinuidades, já uma função Wavelet complexa irá fornecer informação da amplitude e da fase e é mais bem adaptada para capturar comportamentos oscilatórios de séries temporais (Protázio, 2002).
- Suporte - O suporte é a região em que a função é diferente de zero e que quantifica as localizações no tempo e frequência. As Wavelets possuem suporte compacto, o que significa que seu suporte nos números reais é limitado, variando conforme a Wavelet. Devido ao suporte compacto, os coeficientes de uma transformada contêm informações locais de uma função analisada (Da Silva e Pedrini, 2010).
- Formato - A função Wavelet escolhida deve refletir o tipo de características presentes na série temporal. Para séries com picos ou descontinuidades, uma boa escolha seria a Wavelet de Haar, enquanto que para séries mais suaves e com variações mais sutis deve se escolher uma função como a Wavelet Morlet (Protázio, 2002).

A seguir serão apresentadas e ilustradas, sem nenhuma formalidade, algumas funções base para que possa ser visto o formato característico de algumas delas (Misiti et al., 2008).

3.4.1 HAAR

A Wavelet de Haar é a mais antiga e simples de todas e se assemelha a uma função degrau. Esta é ortogonal e possui suporte compacto, ou seja, toda a energia da Wavelet está restrita a um intervalo finito. A função base de Haar é dada pela equação a seguir:

$$\psi(t) = \begin{cases} 1, & \text{se } 0 \leq t < \frac{1}{2} \\ -1, & \text{se } \frac{1}{2} \leq t < 1 \\ 0, & \text{caso contrário} \end{cases} \quad (3.10)$$




Figura 3.11: Wavelet de Haar

3.4.2 DAUBECHIES

Estas são também muito comuns quanto à aplicação, são ortogonais e de suporte compacto. Seu nome é em homenagem a Ingrid Daubechies, a inventora desta família e uma das pessoas mais brilhantes no mundo da pesquisa Wavelet.

Os nomes das funções daubechies são escritos dbn, em que n é a ordem e db o sobrenome da família. A Wavelet db1 é a mesma da função Haar, e as outras são ilustradas na Figura 3.12.




Figura 3.12: Ordens da família Daubechies

Para o caso da db4, a transformação tem quatro Wavelets e coeficientes da função de escala. Os coeficientes da função de escala são

$$\begin{aligned} h_0 &= \frac{1 + \sqrt{3}}{4\sqrt{2}} \\ h_1 &= \frac{3 + \sqrt{3}}{4\sqrt{2}} \\ h_2 &= \frac{3 - \sqrt{3}}{4\sqrt{2}} \\ h_3 &= \frac{1 - \sqrt{3}}{4\sqrt{2}} \end{aligned} \quad (3.11)$$

Cada passo da Transformada de Wavelet aplica a função de escalonamento para a entrada de dados. Se o conjunto de dados original tiver N valores, a função de escalonamento será aplicada na WT para calcular N/2 valores suavizados. Na ordenada Transformada de Wavelet os valores suavizados são armazenados na metade inferior do elemento N do vetor de entrada.

Os valores dos coeficientes Wavelet da função são:

$$\begin{aligned} g_0 &= h_3 \\ g_1 &= -h_2 \\ g_2 &= h_1 \\ g_3 &= -h_0 \end{aligned} \quad (3.12)$$

O escalonamento e funções Wavelet são calculados tomando o produto interno dos coeficientes e quatro valores de dados. As equações são as seguintes:

- Função de escala db4:

$$a_i = h_0 s_{2i} + h_1 s_{2i+1} + h_2 s_{2i+2} + h_3 s_{2i+3} \quad (3.13)$$

$$a[i] = h_0 s[2i] + h_1 s[2i + 1] + h_2 s[2i + 2] + h_3 s[2i + 3] \quad (3.14)$$

- Função Wavelet db4:

$$c_i = g_0 s_{2i} + g_1 s_{2i+1} + g_2 s_{2i+2} + g_3 s_{2i+3} \quad (3.15)$$

$$c[i] = g_0 s[2i] + g_1 s[2i + 1] + g_2 s[2i + 2] + g_3 s[2i + 3] \quad (3.16)$$

3.4.3 BIORTOGONAL

Esta família de Wavelets apresenta a propriedade de fase linear, o que é necessário para a reconstrução de sinais e imagens. O uso de duas Wavelets ao invés de uma mesma função, uma para decomposição e a outra para a reconstrução, é outra característica dessa família de Wavelets. Na Figura 3.13, as funções da esquerda são usadas para a decomposição e as funções da direita para reconstrução.




Figura 3.13: Wavelets Biortogonais

3.4.4 COIFLETS

A família de Coiflets apresenta momentos nulos tanto para a função escala quanto para a função base. O número de momentos nulos nessa onda é representado pela notação que acompanha sua simbologia. Seu nome é em homenagem a R. Coifman, que foi quem pediu a Ingrid Daubechies para construí-la.




Figura 3.14: Wavelets de Coiflets

3.4.5 SYMLETS

As Wavelets Symlets são uma modificação da família Daubechies e suas propriedades são semelhantes. Elas são simétricas e apresentam suporte compacto. Assim como Coiflets, as Symlets também são classificadas conforme o número de momentos nulos.




Figura 3.15: Família Symlets

3.4.6 CHAPÉU MEXICANO

Esta família é a derivada segunda da função gaussiana. Como pode ser visto na Figura 3.16, ela é simétrica, característica que permite examinar os sinais de um modo simétrico e linear na fase. Pertence à família das Wavelets não ortogonais e é definida como:

$$mexh(t) = (1 - t^2)e^{\frac{-t^2}{2}} \quad (3.17)$$




Figura 3.16: Wavelet chapéu mexicano

3.4.7 MORLET

Esta Wavelet não tem função de escala e é definida como:

$$morl(t) = e^{\frac{-t^2}{2}} \cdot e^{j\omega_0 t} \quad (3.18)$$




Figura 3.17: Wavelet Morlet

Nem todas as funções Wavelets podem ser utilizadas em todas as aplicações, algumas famílias só podem ser utilizadas para a Transformada contínua, outras somente para o caso discreto, e outras para ambas as possibilidades. Na Tabela 3.1, estão descrita as restrições e possibilidades das famílias Wavelets:

Tabela 3.1: Possibilidades de uso das famílias Wavelet

	CWT	DWT
Haar	Possível	Possível
Daubechies	Possível	Possível
Biortogonal	Possível	Possível
Coiflets	Possível	Possível
Symlets	Possível	Possível
Chapéu Mexicano	Possível	X
Morlet	Possível	X
Gaussiana	Possível	X
Shannon	Possível na CWT complexa	X
Morlet Complexa	Possível na CWT complexa	X

Capítulo 4

Aplicação da Transformada de Wavelet na Detecção de Oscilações

4.1 INTRODUÇÃO

A detecção de um comportamento oscilante em um processo químico, por exemplo, é de grande importância pelo fato das variabilidades no processo terem um impacto significativo sobre o lucro do mesmo. As oscilações podem permear-se através de uma planta, aumentando a variabilidade e impedindo a fábrica de operar próxima às condições ideais. Elas também podem camuflar outros comportamentos anormais que precisariam de atenção, tais como mau funcionamento de equipamentos e instrumentação, ajuste inadequado do controlador, estrutura de controle inadequada e perturbações externas (Dos Santos, 2010).

Para consultores e engenheiros do controle industrial, a detecção de oscilações em malhas de controle é uma atividade fundamental. As características de interesse são (Thornhill et al., 2003):

- Detecção da presença de uma ou mais oscilações indicadas por um padrão regular nos dados;
- Determinação dos períodos das oscilações, que podem ser usados para inferir a presença de uma oscilação em toda a planta;
- Determinação das magnitudes das oscilações. Uma grande oscilação precisa ser tratada com mais atenção, pois aumenta a variabilidade do processo, enquanto uma oscilação com pequena magnitude normalmente não deve ser um motivo de preocupação.

Existem várias técnicas no domínio do tempo e da frequência para detecção de oscilações. A Figura 4.1 mostra a distribuição de alguns desses métodos para detecção de perturbações em malhas de controle em relação à classificação de comportamento oscilatório e de comportamento não-estacionário (Thornhill e Horsch, 2007).

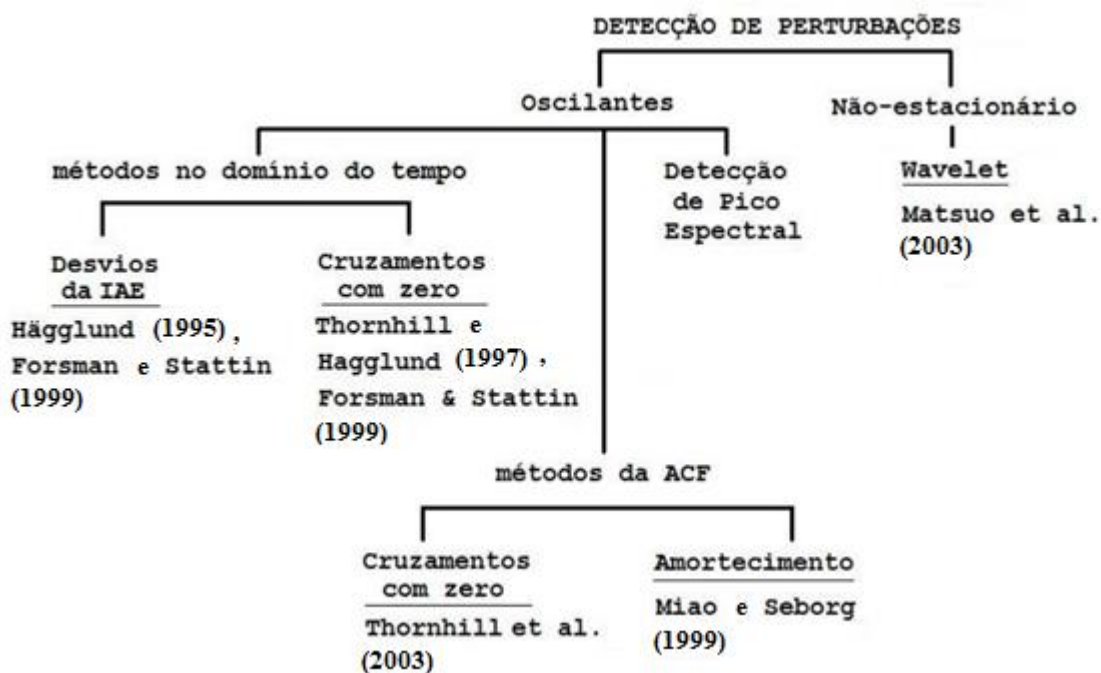


Figura 4.1: Divisão dos métodos para detecção de oscilações em malhas de controle

A Transformada de Wavelet é a técnica principal utilizada no presente trabalho. Sua grande vantagem é a análise multirresolução do sinal, tornando-se um método que pode revelar mais características das oscilações que os métodos tradicionais, o qual pode ser aplicado para sinais não-estacionários e detectar múltiplas oscilações. No caso da detecção, a Transformada de Wavelet será combinada com a autocorrelação ACF para uma análise mais detalhada das oscilações.

4.2 ANÁLISE DE WAVELET NA DETECÇÃO DE OSCILAÇÕES

O algoritmo da análise de Wavelet na detecção de oscilações utilizado neste trabalho dispõe de três passos básicos: dedução do ruído e tendência não estacionária, detecção dos componentes de oscilação e extração e avaliação das oscilações.

Alguns tipos de ruídos podem prejudicar as medições dos dados das variáveis de processo e até mesmo causar falsos cruzamentos por zero em séries de tempo. Além disso, muitas vezes os dados industriais têm a característica de uma mudança lenta no *set-point* e podem sofrer um constante efeito de perturbações externas, que contribuem para uma tendência não estacionária desses dados. Portanto, um pré-processamento dos dados com uma dedução de ruídos e tendências não estacionárias é necessário para garantir a precisão da detecção.

Um filtro é aplicado no sinal analisado para eliminar os indesejáveis ruídos. Já a tendência não estacionária é extraída pelo método de decomposição, utilizando a Transformada Discreta de Wavelet, a qual decompõe o sinal em aproximações e detalhes. Filtros passa-baixa são responsáveis para obter as aproximações e os filtros passa-alta para obter os detalhes. Para dados industriais comuns, a última aproximação, A_n , normalmente representa a tendência não estacionária do sinal. A extração dessa aproximação possibilita a remoção da média não constante do sinal, eliminando a tendência não estacionária (Guo et al., 2014).

Para a detecção dos componentes de oscilação, é aplicada a Transformada Contínua de Wavelet nos dados e o resultado é mostrado em um escalograma. A imagem do sinal no âmbito da CWT desempenha o papel de indicador de oscilações e fornece uma maneira de identificar suas localizações na resolução tempo-frequência, em que revela uma distribuição detalhada da densidade da oscilação. A função Morlet foi escolhida como Wavelet mãe para a CWT no algoritmo de detecção de oscilações. A principal característica na escolha da função Wavelet é a sua semelhança com o sinal analisado, o que garantirá maiores coeficientes Wavelet.

A análise ACF pode ser aplicada para avaliar os conteúdos oscilatórios extraídos. O período de oscilação da ACF de um sinal oscilatório é igual ao período de oscilação deste sinal na tendência do tempo. O modelo de cruzamentos por zero da ACF de um sinal oscilatório revela a presença de uma oscilação de forma mais clara do que os cruzamentos por zero deste sinal na tendência do tempo, pois este método é menos afetado por ruídos.

Cada oscilação tem dois cruzamentos por zero e o intervalo médio entre os cruzamentos por zero é:

$$intervalo = \frac{1}{2} (\bar{T}_p \pm \Delta T_p) \quad (4.1)$$

em que \bar{T}_p é o período médio e ΔT_p uma variação aleatória no período. Portanto \bar{T}_p é duas vezes o valor médio dos intervalos e o desvio padrão do período é $\sigma_{T_p} = 2 \cdot \sigma_{intervalos}$, em que $\sigma_{intervalos}$ é o desvio padrão dos intervalos (Choudhury et al., 2008). Os dez intervalos entre os primeiros onze cruzamentos por zero são usados para o cálculo de \bar{T}_p e σ_{T_p} . Uma oscilação é considerada regular, se o desvio-padrão do período for menor do que um terço do seu valor médio. A regularidade é definida como (Thornhill et al., 2003):

$$r = \frac{1}{3} \cdot \frac{\bar{T}_p}{\sigma_{T_p}} \quad (4.2)$$

Se $r > 1$, rejeita-se a hipótese de intervalos aleatórios e conclui-se que existe uma oscilação padrão no sinal analisado.

A avaliação da intensidade da oscilação é feita através do espectro de potência. O espectro é normalizado antes da filtragem, portanto $\sum P_i = 1$, em que P_i é a potência no i -ésimo canal de frequência. Assim, o espectro filtrado resulta na soma das potências espectrais dos canais de frequência selecionados, ocasionando em uma fração da potência total. Estes valores de potência incluem tanto os componentes oscilatórios quanto os ruídos, pois o filtro utilizado não subtrai o ruído da faixa de frequência desejada. Portanto, se houver uma oscilação regular com $r > 1$, a potência somada no espectro filtrado deverá ser dominada pela potência do sinal oscilatório e pode ser utilizada como uma aproximação para a potência de oscilação. Consequentemente, os conteúdos oscilatórios são extraídos e avaliados através de filtros passa-faixa e análise ACF (Thornhill et al., 2003).

4.3 APLICAÇÃO DA DETECÇÃO NA MALHA DE CONTROLE SIMPLES

No simulador da Figura 2.1, os dados de saída foram coletados com uma taxa de amostragem de 1 segundo, por um período total de 300 segundos. Na Figura 4.2 pode ser vista a variável de saída do processo (PV) e o *setpoint* (linha vermelha):




Figura 4.2: Sinal multioscilar e não estacionário da variável de processo

Wavelet tem a vantagem de analisar dados com múltiplas oscilações e tendências não estacionárias. O sinal da Figura 4.2 é então decomposto via DWT para que seja extraída a aproximação que representa a tendência não estacionária do sinal, e essa decomposição foi feita utilizando a função Wavelet Daubechies nível 5. A aproximação A_5 possui poucos cruzamentos por zero e pode ser identificada como a média não constante de PV, como mostrada na Figura 4.3 (linha vermelha tracejada). Essa aproximação é então extraída, possibilitando a remoção da média não constante do sinal e eliminando a tendência não estacionária (Figura 4.4)




Figura 4.3: Variável de processo e sua tendência não estacionária destacada




Figura 4.4: PV com sua média deslocada

A Figura 4.5 mostra o sinal da Figura 4.4 filtrado, usando um filtro unidimensional baseado em Wavelet. O sinal filtrado é processado usando a CWT, com a função Morlet com frequência de ajuste $\omega_0 = 20$ rad/s, obtendo-se um escalograma, Figura 4.6, que revela uma distribuição detalhada da densidade das oscilações.




Figura 4.5: Sinal de PV filtrado e com sua média deslocada




Figura 4.6: Escalograma da CWT aplicada ao sinal PV

Na Figura 4.6, é fácil observar que existem dois rastros brilhantes no gráfico da CWT, o que implica que o sinal PV contém duas candidatas a oscilações padrões, nas escalas 32 e 84. Os períodos de oscilação das ACFs dos dois conteúdos oscilatórios ilustram os períodos de cada oscilação no domínio do tempo e podem ser vistas na Figura 4.7, respectivamente.




Figura 4.7: ACFs dos conteúdos oscilatórios detectados de PV

A frequência de oscilação (f_{os}) é calculada pela frequência de ajuste (f_0) da função Wavelet utilizada e pela escala (a) correspondente obtida no escalograma da Figura 4.6 (Guo et al., 2014):

$$f_{os} = \frac{f_0}{a} \quad (4.3)$$

em que:

$$f_0 = \frac{\omega_0}{2\pi} \quad (4.4)$$

Nesse caso:

$$f_{os1} = \frac{\omega_0}{2\pi a_1} = \frac{20}{2\pi 32} = 0,0995 \text{ Hz}$$

$$f_{os2} = \frac{\omega_0}{2\pi a_2} = \frac{20}{2\pi 84} = 0,0379 \text{ Hz}$$

A Tabela 4.1 detalha os resultados obtidos:

Tabela 4.1: Resultados obtidos dos conteúdos oscilatórios da PV

Escalas detectadas	Período $\pm \sigma_{Tp}$	Regularidade	Potência (%)
$a_1 = 32$	$10,05s \pm 0,4$	8,37	23,93
$a_2 = 84$	$26,38s \pm 6,38$	1,38	22,76

Portanto, afirma-se que foram detectadas duas oscilações no sinal da variável de processo da Figura 4.2, já que possuem regularidades maiores que a unidade, com períodos de aproximadamente 10 e 26 segundos.

4.4 APLICAÇÃO DA DETECÇÃO NO SISTEMA FCC

No sistema FCC, da Figura 2.4, foi adicionado um *stiction* com *overshoot* na entrada u_2 , com o objetivo de provocar oscilações no sistema, além de ruído branco com potência 0,0004 às saídas do processo. Os dados de saída foram coletados com uma taxa de amostragem de 1 segundo, por um período total de 1000 segundos, os quais são mostrados na Figura 4.8:




Figura 4.8: Sinais das variáveis controladas y_1 e y_2

Na Figura 4.9 estão representadas as tendências não estacionárias das duas variáveis controladas em questão. A decomposição via DWT também foi feita utilizando a função Wavelet Daubechies nível 5. Os sinais deslocados e normalizados, e posteriormente filtrados, podem ser vistos nas Figuras 4.10 e 4.11, respectivamente:




Figura 4.9: Variáveis controladas e suas tendências não estacionárias destacadas




Figura 4.10: Variáveis controladas deslocadas e normalizadas




Figura 4.11: Variáveis controladas filtradas

Aplicou-se então a CWT nas duas variáveis controladas filtradas, utilizando a função Morlet com frequência de ajuste (ω_0) de 20 rad/s em ambos os casos. Os dois escalogramas estão representados na Figura 4.12:




Figura 4.12: Escalogramas da CWT aplicada aos sinais filtrados das variáveis controladas y_1 (escalograma à esquerda) e y_2 (escalograma à direita)

Existe um rastro brilhante em cada gráfico da CWT, na escala de 96 em ambos, implicando que possivelmente cada variável controlada possui um componente oscilatório. As ACFs desses conteúdos oscilatórios são mostradas na Figura 4.13:




Figura 4.13: ACFs dos conteúdos oscilatórios detectados das variáveis controladas y_1 e y_2

Calcula-se então a frequência de cada oscilação. Nesse caso, já que as escalas obtidas nos gráficos da CWT de cada variável controlada foram iguais:

$$f_{os_{y_1}} = f_{os_{y_2}} = \frac{\omega_0}{2\pi a} = \frac{20}{2\pi 96} = 0,033 \text{ Hz}$$

A Tabela 4.2 detalha os resultados obtidos:

Tabela 4.2: Resultados obtidos dos conteúdos oscilatórios das variáveis controladas y_1 e y_2

Variáveis Controladas	Escalas detectadas	Período $\pm \sigma_{T_P}$	Regularidade	Potência (%)
y_1	$a_1 = 96$	$30,3s \pm 0,9$	11,2	50,49
y_2	$a_2 = 96$	$30,3s \pm 0,5$	20,2	53,04

Portanto, afirma-se que foram detectadas duas oscilações com períodos de aproximadamente 30 segundos, uma em cada variável controlada. Essas oscilações possuem as mesmas características, pois foram causadas pela mesma fonte, o que explica a similaridade dos gráficos das ACFs e das CWTs.

Capítulo 5

Uso da Transformada Cruzada de Wavelet e Causalidade de Granger no diagnóstico de oscilações

5.1 INTRODUÇÃO

O diagnóstico completo de oscilações é composto basicamente por três passos: detecção, isolamento e identificação. A detecção, já detalhada no Capítulo 4, informa se existe ou não oscilações persistentes em um certo conjunto de dados. Caso seja confirmada essa oscilação, o próximo passo é o isolamento, que permite determinar a localização da falha. Por fim, completando o diagnóstico, a identificação determina o tipo de perturbação que está causando a oscilação, e para um maior detalhamento, o seu grau de intensidade.

Neste capítulo, primeiramente será feita uma breve descrição da Transformada Cruzada de Wavelet (XWT), ferramenta que será usada para fazer a identificação de oscilações provocadas por diferentes fontes na malha de controle simples descrita na seção 2.2. Posteriormente será analisada a Unidade de Craqueamento Catalítico (seção 2.3), em que será utilizada a Causalidade de Granger para isolar a causa das oscilações, já que se trata de um sistema com múltiplas entradas e múltiplas saídas (MIMO), para em seguida usar a XWT para o diagnóstico da respectiva oscilação.

5.2 TRANSFORMADA CRUZADA DE WAVELET (XWT)

A XWT entre duas séries de tempo X e Y é simplesmente a multiplicação da primeira CWT com o complexo conjugado da segunda CWT (Selvanathan, 2010):

$$W_{xy}(f, \tau) = W_x(f, \tau)W_y^*(f, \tau) \quad (5.1)$$

em que $f \approx \frac{1}{a}$ quando $f_0 = 2\pi$ para a Wavelet Morlet. O fator de escala, a , é inversamente proporcional à frequência central f_0 .

A potência da XWT de duas séries de tempo representa a covariância entre elas. Além disso, essa potência tem uma distribuição conhecida dos níveis de confiança que é proporcional à raiz quadrada do produto de duas distribuições. Isto permite que a potência da Wavelet cruzada seja usada como uma medida quantificada da similaridade de potência entre duas séries de tempo.

A XWT é comumente usada para relacionar duas séries de tempo no domínio tempo-frequência. Kumar e Tale (2015) usou a XWT para analisar e classificar sinais de eletrocardiograma.

5.3 ANÁLISE DA DIFERENÇA DE FASE

Em complemento à análise de Wavelet, a análise do espectro de fase pode ser usada para caracterizar a associação entre sinais. A diferença de fase fornece informações sobre o sinal da relação, ou seja, em fase ou fora de fase. Como a Wavelet Morlet é uma função complexa, a relação da CWT pode ser escrita em termos do módulo $|W_x(f, \tau)|$ e da fase $\phi_x(f, \tau)$, em que (Selvanathan, 2010):

$$\phi_x(f, \tau) = \tan^{-1} \frac{\text{Imag}(W_x(f, \tau))}{\text{Real}(W_x(f, \tau))} \quad (5.2)$$

Da mesma forma, considerando a XWT $W_{xy}(f, \tau)$, a relação de fase entre duas séries de tempo X e Y pode ser calculada usando a relação (Selvanathan, 2010):

$$\phi_{xy}(f, \tau) = \tan^{-1} \frac{\text{Imag}(W_{xy}(f, \tau))}{\text{Real}(W_{xy}(f, \tau))} \quad (5.3)$$

A estimação do espectro de fase no domínio de Fourier entre duas séries de tempo contem relativamente grandes erros comparado com o calculado no domínio Wavelet. Além disso, no domínio Wavelet a diferença de fase é localizada no tempo e na frequência. As setas do gráfico da XWT indicam a direção da diferença de fase entre as variáveis. As setas que apontam para a direita indicam que as variáveis estão em fase, as que apontam para a esquerda indicam fases opostas, para baixo indicam um avanço de fase de 90° e para cima um atraso de fase de 90°. A ideia é que a direção da diferença de fase entre as variáveis exerça um papel crucial na identificação das fontes de oscilações.

5.4 APLICAÇÃO DA XWT NA IDENTIFICAÇÃO DE OSCILAÇÕES

O método da identificação da causa das oscilações usando a XWT foi baseado no trabalho de Selvanathan (2010). Este método necessita da medição da saída do modelo, por isso será utilizada uma estrutura no formato de controle por modelo interno (IMC), como mostrado na Figura 5.1. A XWT da entrada e saída do processo ($W_{uyp}(f, \tau)$) e a XWT da entrada e saída do modelo ($W_{uym}(f, \tau)$) são calculadas e comparadas e os padrões específicos dos gráficos são analisados para determinar as causas das oscilações, utilizando a direção da diferença de fase Wavelet entre as variáveis. São estimadas a razão da magnitude da XWT $\frac{|W_{uyp}(f, \tau)|}{|W_{uym}(f, \tau)|}$, a diferença de fase $\phi_{uyp}(f, \tau) - \phi_{uym}(f, \tau)$ e os ângulos de fase médios de $W_{uyp}(f, \tau)$ e $W_{uym}(f, \tau)$ na frequência fundamental de oscilação.

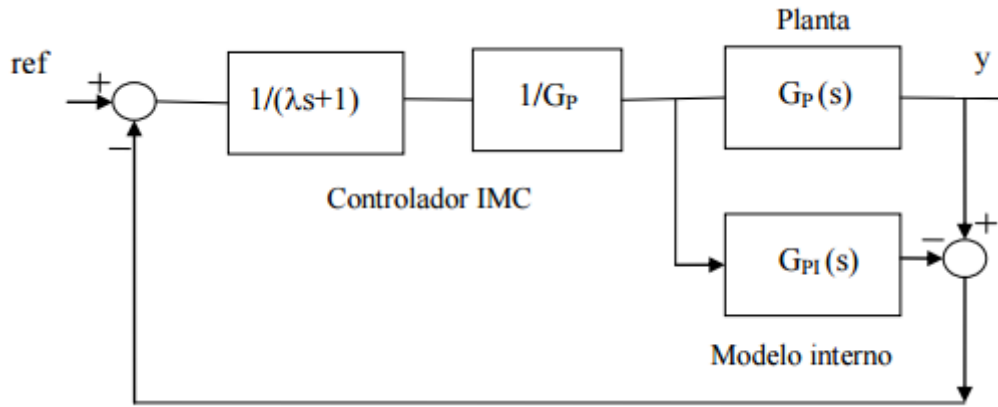


Figura 5.1: Estrutura de controle IMC

Baseando-se nas propriedades da XWT, na diferença de fase Wavelet e na teoria dos sistemas lineares invariantes no tempo, podem ser identificadas como causas de oscilações o *stiction* da válvula, erro planta-modelo (e.g. erro de ganho, erro de atraso e erro da constante de tempo) ou perturbações externas oscilatórias. A metodologia é baseada nos seguintes padrões (Selvanathan, 2010):

- *Stiction* da válvula: se a fonte da oscilação é somente devido ao *stiction* da válvula, o gráfico da XWT deve exibir harmônicos e descontinuidades.
- Erro planta-modelo: Se a fonte de oscilação é devido à incompatibilidade entre planta e modelo, haverá claramente uma única frequência no gráfico da XWT e a causa deve ser identificada entre o erro de ganho, erro de atraso e erro da constante de tempo.
 - Erro de ganho: o erro de ganho teoricamente não afeta o espectro de fase, portanto a diferença de fase entre $W_{uyp}(f, \tau)$ e $W_{uym}(f, \tau)$ será zero na frequência fundamental de oscilação, a razão da magnitude $\frac{|W_{uyp}(f, \tau)|}{|W_{uym}(f, \tau)|}$ será constante, não nula e diferente da unidade na frequência de oscilação e os ângulos médios de fase estimados de $W_{uyp}(f, \tau)$ e $W_{uym}(f, \tau)$ serão teoricamente os mesmos. Além disso, as setas nos gráficos das XWTs terão a mesma direção.

- Erro de atraso: o erro de atraso teoricamente não afeta a magnitude do espectro da XWT, portanto a razão $\frac{|W_{uyp}(f, \tau)|}{|W_{uym}(f, \tau)|}$ será a unidade na frequência de oscilação. Em contrapartida, a diferença de fase entre $W_{uyp}(f, \tau)$ e $W_{uym}(f, \tau)$ será não nula e os ângulos de fase médios serão diferentes. Consequentemente, as setas nos gráficos das XWTs estarão em direções opostas.
- Erro da constante de tempo: o erro da constante de tempo afeta tanto a relação da magnitude quanto o espectro de fase. Os gráficos de $\frac{|W_{uyp}(f, \tau)|}{|W_{uym}(f, \tau)|}$ e $\phi_{uyp}(f, \tau) - \phi_{uym}(f, \tau)$ devem mostrar claramente que o erro da constante de tempo altera significativamente o comportamento do espectro da razão das magnitudes e o espectro de fase. Consequentemente, os ângulos de fase médios de $W_{uyp}(f, \tau)$ e $W_{uym}(f, \tau)$ serão diferentes. As setas nos gráficos das XWTs terão a mesma direção desde que o efeito do erro da constante de tempo no espectro de fase seja mínimo.

5.5 APLICAÇÃO À MALHA DE CONTROLE SIMPLES

Uma estrutura IMC equivalente à malha de controle simples, apresentada na seção 2.2, pode ser vista na Figura 5.2.

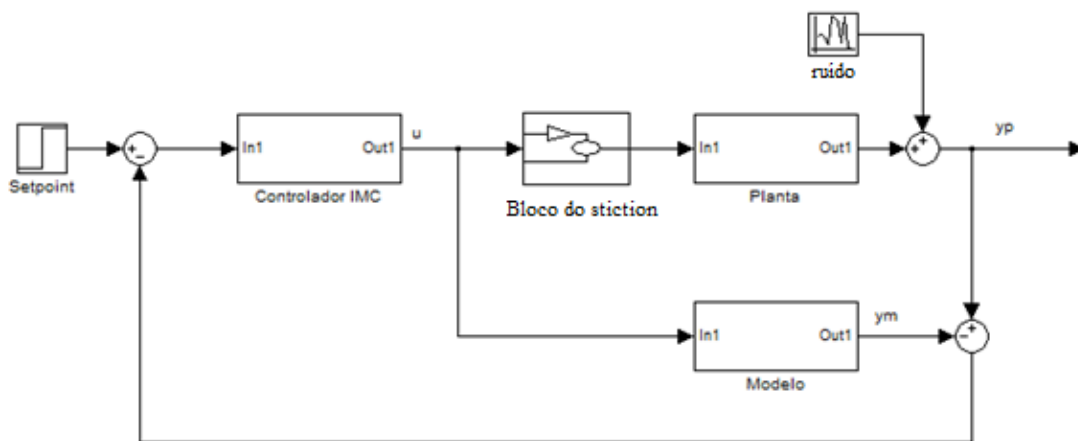


Figura 5.2: Estrutura IMC implementada no Simulink

Na Figura 5.2, a planta é representada pela seguinte função de transferência:

$$G(s) = \frac{6.5(s + 0.3463)}{4.4823s + 1} e^{-3s} \quad (5.4)$$

A malha de controle IMC da Figura 5.2 foi submetida a diferentes tipos de perturbações. Nas subseções seguintes, esses diferentes casos serão analisados e identificados utilizando a XWT.

5.5.1 IDENTIFICAÇÃO DO *STICKION* DA VÁLVULA

Os dados foram coletados com uma taxa de amostragem de 1 segundo, por um período total de 2000 segundos, considerando apenas o *stickion* da válvula. As respostas da saída do processo (yp), saída do modelo (ym) e variável manipulada (mv) podem ser vistas na Figura 5.3. Na Figura 5.4 e 5.5 estão representadas, respectivamente, as XWTs calculadas entre a saída do processo e variável manipulada e entre a saída do modelo e variável manipulada. A comparação desses dois últimos gráficos citados permite a identificação da oscilação, ou seja, determina a sua causa.




Figura 5.3: Comportamento do processo, modelo e variável manipulada para o *stickion* da válvula como fonte de oscilação.




Figura 5.4: Gráfico da XWT entre mv e yp para o *stiction* como fonte de oscilação




Figura 5.5: Gráfico da XWT entre mv e ym para o *stiction* como fonte de oscilação

A análise dos gráficos das XWTs para o *stiction* como fonte de oscilação permite a observação de harmônicos e descontinuidades em ambos. Essa é uma característica padrão de uma válvula aderente, caracterizando o *stiction* como causa da oscilação dos dados em questão.

5.5.2 ERRO PLANTA-MODELO

Se houver incompatibilidade entre a planta e modelo, a causa da oscilação deve ser identificada entre erro de ganho, erro de atraso e erro da constante de tempo. A análise dos gráficos das XWTs entre a entrada e saída do processo, e entre a entrada e saída do modelo, juntamente com as relações da razão da magnitude $\frac{|W_{uyp}(f, \tau)|}{|W_{uym}(f, \tau)|}$ e diferença de fase $\phi_{uyp}(f, \tau) - \phi_{uym}(f, \tau)$, irão caracterizar a causa da oscilação analisada.

Nos casos de erro planta-modelo apresentados a seguir, pressupõe-se que o bloco do *stiction* não está presente no simulador.

5.5.2.1 ERRO DE GANHO

Os dados foram coletados com uma taxa de amostragem de 1 segundo, por um período total de 400 segundos, considerando apenas um erro de ganho na planta, ou processo, adequado para obter uma oscilação persistente nos comportamentos das respostas. Os gráficos da saída do processo (*yp*), saída do modelo (*ym*) e saída do controlador (*u*) podem ser vistos na Figura 5.6. Nas Figuras 5.7 e 5.8 estão representadas, respectivamente, as XWTs calculadas entre a saída do processo e saída do controlador e entre a saída do modelo e saída do controlador.




Figura 5.6: Comportamento do processo, modelo e saída do controlador para o erro de ganho como causa da oscilação.




Figura 5.7: Gráfico da XWT entre u e y_p para o erro de ganho como causa da oscilação




Figura 5.8: Gráfico da XWT entre u e y_m para o erro de ganho como causa da oscilação

A análise dos gráficos das XWTs para o erro de ganho como causa da oscilação mostra que as setas dos dois gráficos apontam para a mesma direção na frequência fundamental de oscilação, garantindo que não há diferença de fase entre eles. Para o complemento do diagnóstico, é necessário nesse caso analisar as relações da razão da magnitude $\frac{|W_{uyp}(f, \tau)|}{|W_{uym}(f, \tau)|}$ (Figura 5.9) e diferença de fase $\phi_{uyp}(f, \tau) - \phi_{uym}(f, \tau)$ (Figura 5.10) na frequência fundamental de oscilação.




Figura 5.9: Razão da magnitude da XWT entre u e yp e da XWT entre u e ym para o erro de ganho como causa da oscilação




Figura 5.10: Diferença de fase da XWT entre u e yp e da XWT entre u e ym para o erro de ganho como causa da oscilação

A análise das Figuras 5.9 e 5.10 comprova que o erro de ganho não afeta o espectro de fase, portanto a diferença de fase entre $W_{uyp}(f, \tau)$ e $W_{uym}(f, \tau)$ foi zero na frequência fundamental de oscilação. A razão da magnitude foi constante, não nula e diferente da unidade e os ângulos médios de fase estimados de $W_{uyp}(f, \tau)$ e $W_{uym}(f, \tau)$ se mostraram exatamente iguais. O conjunto dessas características aponta para um erro de ganho como causa da oscilação, identificado com um pouco mais de quatro vezes (Figura 5.9) o ganho do modelo do sistema.

5.5.2.2 ERRO DE ATRASO

Os dados foram coletados com uma taxa de amostragem de 1 segundo, por um período total de 1000 segundos, considerando apenas um erro de atraso na planta, adequado para obter uma oscilação persistente nos comportamentos das respostas. Os gráficos da saída do processo (yp), saída do modelo (ym) e saída do controlador (u) podem ser vistos na Figura 5.11. Nas Figuras 5.12 e 5.13 estão representadas, respectivamente, as XWTs calculadas entre a saída do processo e saída do controlador e entre a saída do modelo e saída do controlador.




Figura 5.11: Comportamento do processo, modelo e saída do controlador para o erro de atraso como causa da oscilação.




Figura 5.12: Gráfico da XWT entre u e yp para o erro de atraso como causa da oscilação




Figura 5.13: Gráfico da XWT entre u e ym para o erro de atraso como causa da oscilação

A análise dos gráficos das XWTs para o erro de atraso como causa da oscilação mostra que as setas dos dois gráficos apontam claramente para direções diferentes na frequência fundamental de oscilação, garantindo que há diferença de fase entre eles. Para o complemento do diagnóstico, são necessárias as análises da razão da magnitude $\frac{|w_{uyp}(f, \tau)|}{|w_{uym}(f, \tau)|}$ (Figura 5.14) e diferença de fase $\phi_{uyp}(f, \tau) - \phi_{uym}(f, \tau)$ (Figura 5.15) na frequência fundamental de oscilação.




Figura 5.14: Razão da magnitude da XWT entre u e yp e da XWT entre u e ym para o erro de atraso como causa da oscilação




Figura 5.15: Diferença de fase da XWT entre u e y_p e da XWT entre u e y_m para o erro de atraso como causa da oscilação

A análise das Figuras 5.14 e 5.15 comprova que o erro de atraso afeta o espectro de fase, pois a diferença de fase entre $W_{uyp}(f, \tau)$ e $W_{uym}(f, \tau)$ foi de 1,262 rad/s na frequência fundamental de oscilação. A razão da magnitude foi constante e próxima da unidade, o que comprova que o erro de atraso não afeta a magnitude do espectro da XWT, e os ângulos médios de fase estimados de $W_{uyp}(f, \tau)$ e $W_{uym}(f, \tau)$ foram 1,8041 rad/s e 0,5443 rad/s respectivamente. O conjunto dessas características aponta para o erro de atraso como causa da oscilação nesse caso.

A razão da diferença de fase das duas XWTs e um período completo fornece a intensidade relativa do erro de atraso, que caracteriza a porcentagem do atraso correspondente ao período total da oscilação:

$$Erro\ de\ atraso(\%) = \frac{\phi_{uyp}(f, \tau) - \phi_{uym}(f, \tau)}{2\pi} \quad (5.5)$$

Nesse caso:

$$Erro\ de\ atraso(\%) = \frac{1,262\ rad/s}{2\pi\ rad/s} = 20\%$$

Para uma análise mais específica é necessário conhecer o período da oscilação. Na Figura 5.16, pode ser visto o detalhamento do período de oscilação através de uma aproximação no sinal da saída do processo:




Figura 5.16: Estimação do período de oscilação de y_p para o erro de atraso como causa da oscilação

Portanto, o período de oscilação (T_o) é de 50 segundos. O erro de atraso pode ser calculado através da relação:

$$Erro\ de\ atraso = \frac{\phi_{uyp}(f, \tau) - \phi_{uym}(f, \tau)}{2\pi} \times T_o \quad (5.6)$$

Nesse caso:

$$Erro\ de\ atraso = \frac{1,262\ rad/s}{2\pi\ rad/s} \times 50s = 10s$$

Portanto, foi identificado um erro de atraso de 10 segundos, o que corresponde a 20% do período total da oscilação causada.

5.5.2.3 ERRO DA CONSTANTE DE TEMPO

Os dados foram coletados com uma taxa de amostragem de 1 segundo, por um período total de 1000 segundos, considerando apenas um erro da constante de tempo na planta, adequado para obter uma oscilação persistente nos comportamentos das respostas. Os gráficos da saída do processo (y_p), saída do modelo (y_m) e saída do controlador (u) podem ser vistos na Figura 5.17. Nas Figuras 5.18 e 5.19 estão representadas, respectivamente, as XWTs calculadas entre a saída do processo e saída do controlador e entre a saída do modelo e saída do controlador.




Figura 5.17: Comportamento do processo, modelo e saída do controlador para o erro da constante de tempo como causa da oscilação.




Figura 5.18: Gráfico da XWT entre u e y_p para o erro da constante de tempo como causa da oscilação




Figura 5.19: Gráfico da XWT entre u e y_m para o erro da constante de tempo como causa da oscilação

A análise dos gráficos das XWTs para o erro da constante de tempo como causa da oscilação mostra que as setas dos dois gráficos apontam para direções diferentes na frequência fundamental de oscilação, garantindo que há diferença de fase entre eles. Para o complemento do diagnóstico, é necessário analisar as relações da razão da magnitude $\frac{|W_{uyp}(f, \tau)|}{|W_{uym}(f, \tau)|}$ (Figura 5.20) e diferença de fase $\phi_{uyp}(f, \tau) - \phi_{uym}(f, \tau)$ (Figura 5.21) na frequência fundamental de oscilação.




Figura 5.20: Razão da magnitude da XWT entre u e y_p e da XWT entre u e y_m para o erro da constante de tempo como causa da oscilação




Figura 5.21: Diferença de fase da XWT entre u e y_p e da XWT entre u e y_m para o erro da constante de tempo como causa da oscilação

A análise das Figuras 5.20 e 5.21 comprova que a oscilação afeta tanto a relação da magnitude quanto o espectro de fase, pois a razão da magnitude foi constante, não nula e diferente da unidade e a diferença de fase entre $W_{uyp}(f, \tau)$ e $W_{uym}(f, \tau)$ foi de 1,109 rad/s na frequência fundamental de oscilação. Os ângulos médios de fase estimados de $W_{uyp}(f, \tau)$ e $W_{uym}(f, \tau)$ foram 1,8868 rad/s e 0,7718 rad/s respectivamente. O conjunto dessas características aponta para o erro da constante de tempo como causa da oscilação. Como esse tipo de erro afeta tanto a relação da magnitude quanto a diferença de fase, é necessário analisar a intensidade das alterações de ganho e atraso do sistema. Nesse caso, a alteração no ganho foi de quase duas vezes (Figura 5.20) o ganho do modelo do sistema.

Estimando o período da oscilação (Figura 5.22), e das equações (5.5) e (5.6), tem-se:




Figura 5.22: Estimação do período de oscilação de y_p para o erro da constante de tempo como causa da oscilação

$$\text{Erro de atraso}(\%) = \frac{1,109 \text{ rad/s}}{2\pi \text{ rad/s}} = 17,65 \%$$

$$\text{Erro de atraso} = \frac{1.109 \text{ rad/s}}{2\pi \text{ rad/s}} \times 33 \text{ s} = 5,82 \text{ s}$$

Portanto, foi identificado um erro da constante de tempo, que provocou uma alteração no ganho de quase duas vezes o ganho do modelo do sistema e um atraso de 5,82 segundos, o que corresponde a 17.65% do período total da oscilação causada.

5.5.3 OSCILAÇÕES DEVIDO AO ERRO DE GANHO E PERTURBAÇÃO EXTERNA OSCILATÓRIA

Os dados foram coletados com uma taxa de amostragem de 1 segundo, por um período total de 2000 segundos, considerando um erro de ganho entre 1000 e 2000 segundos, adequado para obter uma oscilação persistente nos comportamentos das respostas, e uma perturbação externa oscilatória durante todo o tempo de simulação. Os gráficos da saída do processo (y_p), saída do modelo (y_m) e saída do controlador (u) podem ser vistos na Figura 5.23. Nas Figuras 5.24 e 5.25 estão representadas, respectivamente, as XWTs calculadas entre a saída do processo e saída do controlador e entre a saída do modelo e saída do controlador.

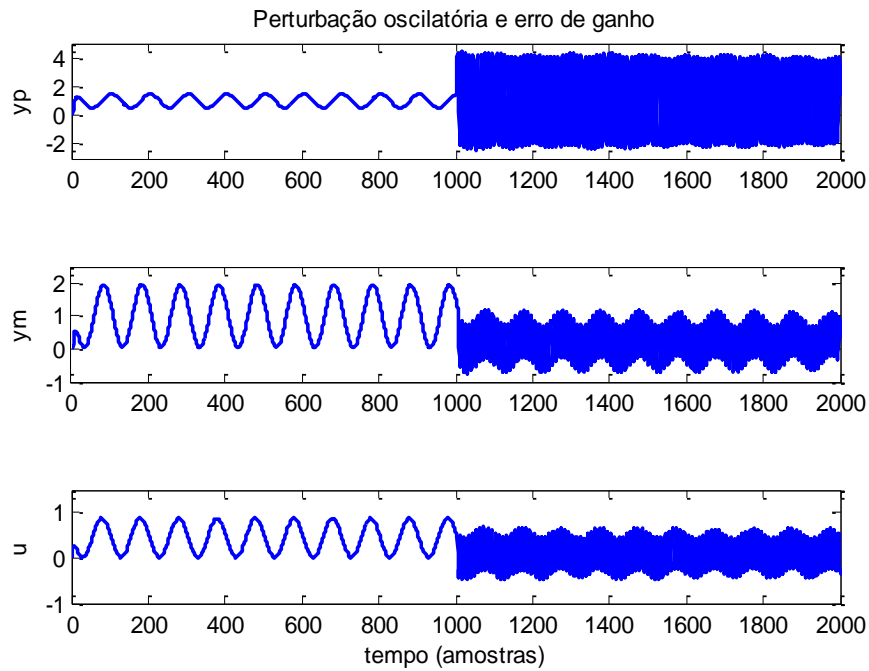


Figura 5.23: Comportamento do processo, modelo e saída do controlador para o erro de ganho e perturbação oscilatória como causas das oscilações




Figura 5.24: Gráfico da XWT entre u e y_p para o erro de ganho e perturbação oscilatória como causas das oscilações




Figura 5.25: Gráfico da XWT entre u e y_m para o erro de ganho e perturbação oscilatória como causas das oscilações

É possível observar dois componentes oscilatórios pela análise dos gráficos das XWTs. Entre 1000 e 2000 amostras, em frequência de aproximadamente 0,1 Hz, nota-se uma única oscilação, bem clara e destacada, em que não houve mudança de fase, caracterizando-se como um erro de ganho como fonte dessa oscilação. Outro componente oscilatório pode ser visualizado nos gráficos durante todo o tempo de simulação, em uma frequência de 0,01 Hz. Este componente não se apresenta com uma faixa de frequência tão bem definida e isolada como os casos apresentados até aqui de incompatibilidade entre planta e modelo. Além disso, essa oscilação não pode ser devido ao erro de atraso, pois a presença do erro de atraso e erro de ganho ao mesmo tempo, necessários para causar oscilações persistentes, provavelmente levariam o sistema à instabilidade (Selvanathan, 2010). Assim, pode-se concluir que o ciclo possui um componente oscilatório causado por uma perturbação externa oscilatória de 0,01 Hz durante todo o período do sinal, e outro componente oscilatório causado por um erro de ganho entre o período de 1000 e 2000 segundos, como fontes de oscilações.

5.6 INTRODUÇÃO À CAUSALIDADE DE GRANGER

Considerando um conjunto de dados de séries temporais, uma das mais populares definições de causalidade é a Causalidade de Granger (GC). Devido à sua simplicidade, facilidade de interpretação e implementação, a GC tem encontrado amplas aplicações na economia. Recentemente essa técnica vem ganhando grande atenção em muitas outras áreas para extrair informações dinâmicas úteis e no estudo das relações internas causais. A GC constrói uma conexão linear entre causalidade e predição, e emprega um teste de hipóteses estatísticas para determinar se uma série de tempo é eficiente na previsão de outra (Yuan e Qin, 2014). Este trabalho usa a GC para analisar as relações de causa e efeito em oscilações. Juntamente com a XWT, ela fará o isolamento e identificação de oscilações em um processo industrial.

Pela GC, considerando X_1 e X_2 séries temporais, X_2 causa X_1 se o erro de predição do modelo autorregressivo de X_1 é reduzido pela adição da última informação de X_2 (Zuqui e Munaro, 2015). A teoria da GC apresentada aqui se baseia no trabalho de Yuan e Qin, 2014.

5.6.1 CAUSALIDADE DE GRANGER NO DOMÍNIO DO TEMPO

Para duas séries de tempo $X_1(t)$ e $X_2(t)$, o modelo autorregressivo de cada sinal é dado por (Yuan e Qin, 2014):

$$X_1(t) = \sum_{l=1}^k a_{11,l} X_1(t-l) + \sum_{l=1}^k a_{12,l} X_2(t-l) + e_1(t) \quad (5.7)$$

$$X_2(t) = \sum_{l=1}^k a_{21,l} X_1(t-l) + \sum_{l=1}^k a_{22,l} X_2(t-l) + e_2(t) \quad (5.8)$$

em que $a_{ij,l}$ são os coeficientes AR (*autoregressive*), $e_i(t)$ são os erros de predição do modelo e k é a ordem do modelo. As equações (5.7) e (5.8) são referidas como modelo

sem restrições ou modelo completo. Como alternativa, umas das variáveis X_1 ou X_2 podem ser excluídas para realizar a modelagem AR em cada série de tempo, como segue:

$$X_1(t) = \sum_{l=1}^k b_{1,l} X_1(t-l) + e_{1(2)}(t) \quad (5.9)$$

$$X_2(t) = \sum_{l=1}^k b_{2,l} X_2(t-l) + e_{2(1)}(t) \quad (5.10)$$

em que $e_{i(j)}(t)$ refere-se ao erro de predição de um modelo que prevê a i -ésima variável pela exclusão da j -ésima variável. Se a variância de $e_i(t)$ é menor do que a de $e_{i(j)}(t)$ com alguma significância estatística, a predição das séries temporais $X_i(t)$ é significativamente mais precisa, incorporando os valores anteriores de $X_j(t)$. Como consequência, conclui-se que existe um efeito causal de $X_j(t)$ para $X_i(t)$. A diferença das variâncias pode ser quantificada pela seguinte relação:

$$F_{j \rightarrow i} = \ln \frac{\text{var}(e_{i(j)})}{\text{var}(e_i)} \quad (5.11)$$

A generalização da GC bivariada para o caso multivariada é direta. Definindo:

$$A_{ij}(q^{-1}) = \sum_{l=1}^k a_{ij,l} q^{-l} \quad (5.12)$$

em que q^{-1} é o operador de deslocamento. As equações (5.7) e (5.8) podem ser estendidas para o caso multivariável, como segue para um sistema de n variáveis:

$$\begin{bmatrix} X_1(t) \\ X_2(t) \\ \vdots \\ X_n(t) \end{bmatrix} = \begin{bmatrix} A_{11}(q^{-1}) & A_{12}(q^{-1}) & \dots & A_{n1}(q^{-1}) \\ A_{21}(q^{-1}) & A_{22}(q^{-1}) & \dots & A_{n2}(q^{-1}) \\ \vdots & \vdots & \ddots & \vdots \\ A_{n1}(q^{-1}) & A_{n2}(q^{-1}) & \dots & A_{nn}(q^{-1}) \end{bmatrix} \begin{bmatrix} X_1(t) \\ X_2(t) \\ \vdots \\ X_n(t) \end{bmatrix} + \begin{bmatrix} e_1(t) \\ e_2(t) \\ \vdots \\ e_n(t) \end{bmatrix} \quad (5.13)$$

É dito que X_j causa X_i se excluindo X_j , a habilidade de prever X_i for diminuída, mesmo que todas as outras variáveis sejam incluídas no modelo de regressão. Se cada variável X_j é excluída uma vez na previsão de todas as outras variáveis X_i , $\forall i \neq j$, haverá $(n - 1) \times n$ sequências de erros de predição $e_{i(j)}(t)$ e, correspondentemente, $(n - 1) \times n$ variâncias denotadas como $\sigma_{i(j)}^2 = \text{var}(e_{i(j)})$. Pode ser formada a seguinte matriz de causa-efeito de variâncias, em que o ij -ésimo elemento é a variância da predição da i -ésima linha de variáveis pela exclusão da j -ésima coluna, para $i \neq j$. Os elementos diagonais dão as variâncias residuais dos n modelos completos, denotados por $\sigma_i^2 = \text{var}(e_i)$.

$$\begin{array}{ccccc} & (X_1) & (X_2) & \dots & (X_n) \\ X_1 & \sigma_1^2 & \sigma_{1(2)}^2 & \dots & \sigma_{1(n)}^2 \\ X_2 & \sigma_{2(1)}^2 & \sigma_2^2 & \dots & \sigma_{2(n)}^2 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ X_n & \sigma_{n(1)}^2 & \sigma_{n(2)}^2 & \dots & \sigma_n^2 \end{array} \quad (5.14)$$

Espera-se que os elementos diagonais da matriz sejam menores que os outros elementos da mesma linha, uma vez que os modelos completos usam mais entradas nos modelos de regressão para ajustar os dados. Se a variável X_j tiver um efeito causal significativo sobre a variável X_i , o ij -ésimo elemento na matriz deve ser significativamente maior que o elemento ii -ésimo. Portanto, a GC da variável j para a variável i , dadas todas as outras variáveis, é medida por:

$$F_{j \rightarrow i} = \ln \frac{\sigma_{i(j)}^2}{\sigma_i^2} \quad (5.15)$$

que é o índice GC. No entanto, a significância estatística precisa ser estabelecida antes de ser tomada uma conclusão sobre a relação de causalidade. Considerando dois modelos 1 e 2, o modelo 1 é o modelo restrito com parâmetros p_1 , enquanto o modelo 2 é o modelo completo com parâmetros p_2 , em que $p_2 > p_1$. O modelo completo pode ajustar os dados pelo menos tão bem quanto o modelo restrito. A ideia é determinar se o modelo 2 fornece uma significância melhor de ajuste para os dados que o modelo 1. O seguinte F teste é aplicado:

$$\frac{(RSS_1 - RSS_2)/(p_2 - p_1)}{RSS_2/(no - p_2)} \sim F_{p_2 - p_1, no - p_2} \quad (5.16)$$

em que RSS_i é a soma dos quadrados dos resíduos no modelo i , e no é o número total de observações. Se o p -valor é menor que a distribuição F com um nível significativo α (normalmente 0,01 ou 0,05), a hipótese nula de que não existe causalidade pode ser rejeitada.

5.6.2 CAUSALIDADE DE GRANGER ESPECTRAL

A análise espectral de Granger foca a análise em uma faixa de frequência específica. Para múltiplas séries de tempo autorregressivas e não determinísticas, considerando dados de uma série de tempo, a potência na frequência específica pode ser decomposta em uma parte intrínseca e outra que é predita pelos dados de outra série de tempo. Para extrair a GC no domínio da frequência, realiza-se a Transformada de Fourier de (5.7) e (5.8) e é obtido:

$$\begin{bmatrix} A_{11}(f) & A_{12}(f) \\ A_{21}(f) & A_{22}(f) \end{bmatrix} \begin{bmatrix} X_1(f) \\ X_2(f) \end{bmatrix} = \begin{bmatrix} E_1(f) \\ E_2(f) \end{bmatrix} \quad (5.17)$$

em que os componentes da matriz coeficiente $[A_{ij}(f)]$ são $A_{ij}(f) = \delta_{ij} - \sum_{l=1}^k a_{ij,l} e^{-2\pi f l}$. Designando a função de transferência da matriz $H(f) = [A_{ij}(f)]^{-1}$, a equação (5.17) pode ser rescrita como:

$$\begin{bmatrix} X_1(f) \\ X_2(f) \end{bmatrix} = \begin{bmatrix} H_{11}(f) & H_{12}(f) \\ H_{21}(f) & H_{22}(f) \end{bmatrix} \begin{bmatrix} E_1(f) \\ E_2(f) \end{bmatrix} \quad (5.18)$$

Portanto, a matriz densidade espectral $S(f)$ segue como:

$$S(f) = \langle X(f)X^*(f) \rangle = H(f)\Sigma H^*(f) \quad (5.19)$$

em que Σ é a covariância dos resíduos do modelo completo e $X^*(f)$ é a transposta de Hermit de $X(f)$. Para o processo de X_1 , multiplica-se os dois lados de (5.17) por

$$\begin{bmatrix} 1 & 0 \\ -\Sigma_{12}/\Sigma_{11} & 1 \end{bmatrix} \quad (5.20)$$

e é obtido:

$$\begin{bmatrix} X_1(f) \\ X_2(f) \end{bmatrix} = \begin{bmatrix} \tilde{H}_{11}(f) & \tilde{H}_{12}(f) \\ \tilde{H}_{21}(f) & \tilde{H}_{22}(f) \end{bmatrix} \begin{bmatrix} E_1(f) \\ \tilde{E}_2(f) \end{bmatrix} \quad (5.21)$$

em que

$$\tilde{E}_2(f) = E_2(f) - \frac{\Sigma_{12}}{\Sigma_{11}} E_1(f) \quad (5.22)$$

e

$$\begin{aligned} \begin{bmatrix} \tilde{H}_{11}(f) & \tilde{H}_{12}(f) \\ \tilde{H}_{21}(f) & \tilde{H}_{22}(f) \end{bmatrix} &= \begin{bmatrix} H_{11}(f) & H_{12}(f) \\ H_{21}(f) & H_{22}(f) \end{bmatrix} \begin{bmatrix} 1 & 0 \\ -\Sigma_{12}/\Sigma_{11} & 1 \end{bmatrix}^{-1} \\ &= \begin{bmatrix} H_{11}(f) + \frac{\Sigma_{12}}{\Sigma_{11}} H_{12}(f) & H_{12}(f) \\ H_{21}(f) + \frac{\Sigma_{12}}{\Sigma_{11}} H_{11}(f) & H_{22}(f) \end{bmatrix} \end{aligned} \quad (5.23)$$

A equação (5.22) faz a não correlação entre \tilde{E}_2 e E_1 . O espectro de $X_1(t)$ é representado em duas partes:

$$S_{11}(f) = \tilde{H}_{11}(f) \Sigma_{11} \tilde{H}_{11}^*(f) + \tilde{H}_{12}(f) \tilde{\Sigma}_{22} \tilde{H}_{12}^*(f) \quad (5.24)$$

em que $\tilde{\Sigma}_{22} = \Sigma_{22} - (\Sigma_{12}^2/\Sigma_{11})$. Portanto, a Causalidade de Granger espectral de X_2 para X_1 na frequência f é

$$I_{2 \rightarrow 1}(f) = \ln \frac{S_{11}(f)}{S_{11}(f) - (\Sigma_{22} - (\Sigma_{12}^2/\Sigma_{11})) |H_{12}(f)|^2} \quad (5.25)$$

que pode ser interpretada da seguinte forma: na frequência em questão, a quantidade de potência de X_1 que pode ser prevista pelos dados passados de X_2 .

5.7 APLICAÇÃO AO SISTEMA FCC

Conforme mostrada na seção 4.4, foram detectadas duas oscilações com período de 30 segundos, uma em cada variável controlada. O próximo passo será a aplicação da GC para isolar a causa da oscilação, ou seja, determinar qual entrada está perturbando o sistema.

Para este caso, são consideradas as medições das saídas do sistema, como no caso da seção 4.4, além das medições das entradas considerando ruído branco com potência de 0,00025.

5.7.1 ISOLAMENTO DA OSCILAÇÃO USANDO A CAUSALIDADE DE GRANGER

Para a aplicação da GC foi utilizado o *toolbox* MVGC (*Multivariate Granger Causality*), desenvolvido por Barnett e Seth (2014), implementado no MATLAB™.

As quatro variáveis a serem analisadas (mv_1 , mv_2 , y_1 e y_2) podem ser vistas na Figura 5.26:




Figura 5.26: Variáveis manipuladas (mv_1 e mv_2) e variáveis controladas (y_1 e y_2)

Pode-se observar que existe uma oscilação padrão em comum nas variáveis. É aplicada então a GC no domínio do tempo para todas as quatro variáveis (Figura 5.27):




Figura 5.27: Mapa da causalidade de Granger no domínio do tempo

A interpretação desse mapa da GC é simples e direta. As colunas representam quem causa e as linhas quem sofre a influência, ou seja, a cor de cada quadrado representa o quanto que a variável, de cada coluna, causa em outra variável, de cada linha. Pela análise rápida da Figura 5.27, pode ser observado que a variável manipulada mv_2 está causando em todas as outras três variáveis (mv_1 , y_1 e y_2), sendo que a variável que mais está sofrendo influência da perturbação é a variável controlada y_2 . Além disso, a variável manipulada mv_2 não está sofrendo influência de nenhuma das outras três variáveis, ao contrário das outras três variáveis em questão que são influenciadas.

A sugestão de causa-efeito do mapa da GC no domínio do tempo pode ser reforçada pelo seu espectro (Figura 5.28):

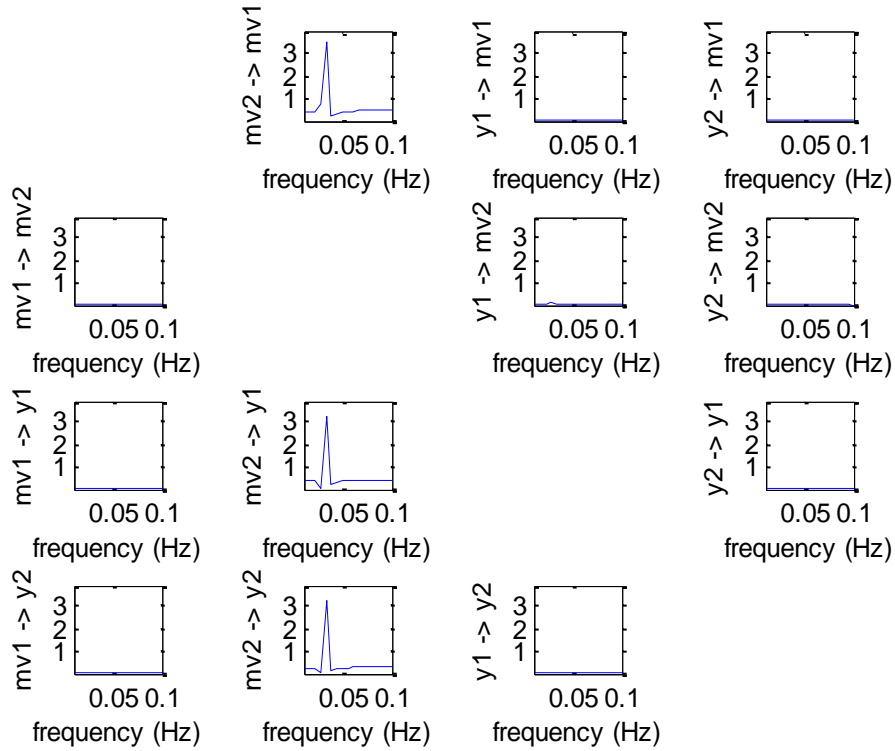


Figura 5.28: Magnitude da causalidade de Granger espectral

O gráfico da GC espectral mostra altos picos em torno da frequência de oscilação (0,033 Hz) já detectada na seção 4.4, que indica a presença de uma oscilação padrão em comum. O espectro reforça também que mv_2 não sobre influência de nenhuma das outras três variáveis.

Portanto, com a análise dos gráficos da GC no domínio do tempo e seu espectro, pode ser concluído que a variável manipulada mv_2 é a fonte de oscilações do processo simulado.

5.7.2 IDENTIFICAÇÃO DA OSCILAÇÃO NO SISTEMA FCC UTILIZANDO XWT

De posse da informação de que a variável manipulada mv_2 é a fonte de oscilação e a variável controlada y_2 é quem sofre a maior influência da perturbação, foi utilizado a

XWT para completar o diagnóstico do sistema, ou seja, identificar o que está causando essa oscilação na variável isolada.

Nas Figuras 5.29 e 5.30 estão representadas, respectivamente, as XWTs calculadas entre a saída do processo (y_2) e variável manipulada (mv_2) e entre a saída do modelo (ym_2) e variável manipulada (mv_2), sendo que os dados da saída do modelo foram coletados na programação interna do controlador MPC.




Figura 5.29: Gráfico da XWT entre mv_2 e y_2 do sistema FCC




Figura 5.30: Gráfico da XWT entre mv_2 e ym_2 do sistema FCC

A análise dos dois gráficos das XWTs permite a observação de harmônicos e descontinuidades em ambos, caracterizando o *stiction* como fonte da oscilação, o qual está atuando na segunda entrada do sistema em questão.

Capítulo 6

Conclusões e Recomendações

A presente dissertação teve como objetivo o diagnóstico completo (detecção, isolamento e identificação) de oscilações em malhas de controle de processos utilizando a análise de Wavelet combinada com outras técnicas de análise de sinais, tais como Função de Autocorrelação e Causalidade de Granger. As técnicas foram testadas em uma malha de controle simples e um sistema FCC.

A motivação deste trabalho foi o fato de que as oscilações são consideradas uma das principais causas da degradação do desempenho em malhas de controle, as quais, especialmente múltiplas, causadas principalmente pelo projeto inadequado do sistema de controle e má configuração do processo, perturbações externas, não-linearidade em válvulas de controle, ajuste agressivo do controlador entre outras, têm um efeito negativo sobre o desempenho dessas malhas e podem forçar a planta a operar em condições abaixo do ideal.

A principal técnica utilizada foi a análise de Wavelet, a qual fornece a possibilidade de análise multirresolução do sinal, tanto no tempo quanto na frequência, e usa grandes escalas para mostrar as características globais do sinal e pequenas escalas para mostrar os detalhes do mesmo. Além disso, Wavelet é capaz de detectar oscilações múltiplas e pode analisar sinais não estacionários. Com isso, torna-se um método que pode revelar mais características das oscilações do que os métodos tradicionais.

Primeiramente a detecção foi feita sobre uma malha de controle simples, considerando o *stiction* da válvula e uma perturbação externa oscilatória como fontes das perturbações. A análise de Wavelet, combinada com a ACF, detectaram com êxito as duas oscilações na variável de processo. Posteriormente, a detecção foi aplicada sobre o sistema FCC, em que foi inserido um *stiction* em uma das entradas. Foram detectadas duas oscilações, uma em cada uma das duas variáveis controladas.

O complemento do diagnóstico também foi aplicado nos dois estudos de caso. A malha de controle simples foi convertida a um modelo equivalente no formato IMC, o qual foi submetido a diferentes tipos de anormalidades, como *stiction* da válvula, erro de ganho, erro de atraso, erro da constante de tempo e perturbação externa oscilatória, as quais foram identificadas via XWT com êxito. Para o sistema FCC, com o *stiction* inserido em uma das entradas, primeiramente foi aplicada a Causalidade de Granger para isolar a fonte da perturbação, no caso a entrada referente à variável manipulada mv_2 . De posse dessa informação, a XWT foi aplicada para finalizar o diagnóstico, concluindo que a fonte da perturbação do sistema foi o *stiction* atuando na segunda entrada. Uma pequena desvantagem do uso da XWT no diagnóstico de oscilações é a necessidade do uso dos dados da saída do modelo para que a análise seja feita, e nem todas as estruturas de controle possuem essa informação.

Como recomendações para trabalhos futuros, sugere-se a adição de técnicas que diminuam o esforço computacional, para o caso de um sistema com várias entradas e várias saídas. Como exemplo, a Análise de Componentes Principais (PCA), que pode converter um conjunto de observações de variáveis possivelmente correlacionadas a um conjunto de componentes principais, o qual possui um número de variáveis menor ou igual ao número de variáveis originais.

Referências Bibliográficas

BARNETT, L.; SETH, A.K. (2014). The MVGC Multivariate Granger Causality Toolbox: a New Approach to Granger-causal Inference. *Journal of Neuroscience Methods*, **223**(1): 50-68

BECKMAN, D., JURY, F. (1997). *Reducing process variability with control valves*, Internal Report (November), Fisher Controls International Inc, Marshalls town, Iowa.

BENDJAMA, H.; BOUHOUCHE, S.; BOUCHERIT, M.S. (2012). Application of Wavelet Transform for Fault Diagnosis in Rotating Machinery. *International Journal of Machine Learning and Computing*, **2**(1): 82-87.

BIALKOWSKI, W, L. (1993). Dreams versus reality: a view from both sides of the gap. *Pulp and Paper Canada*, **94**(11): 19-27.

CHOUDHURY, M.A.A.S.; SHAH, S.L.; THORNHILL, N.F. (2008). *Diagnosis of Process Nonlinearities and Valve Stiction – Data Driven Approaches*. Springer, London.

CHOUDHURY, M.A.A.S.; THORNHILL, N.F.; SHAH, S.L. (2005). Modelling Valve Stiction, *Control Engineering Practice*, **13**(5): 641-658.

COSTA, C.S.; MONTEIRO, U.A.B.V.; PINTO, L.A.V. (2012). Uso da Transformada Discreta de Wavelet no pré-processamento de sinais de vibração de caixas de engrenagem. In: *Anais do 24º Congresso Nacional de Transporte Aquaviário, Construção Naval e Offshore*, Rio de Janeiro, Brasil.

DA SILVA, R.D.; PEDRINI, H. (2010). Estudo comparativo de transformadas Wavelets para descrição de texturas. In: *Anais do VI Workshop de Visão Computacional (WVC 2010)*, São Paulo, Brasil.

DE CAMPOS, P.R.B.; DE CAMPOS, C.A.B. (2014). Sintonia de controladores para processos didáticos sem atraso de transporte. In: *Anais do XLII Congresso Brasileiro de Educação em Engenharia (XLII COBENGE)*, Juiz de Fora, Brasil.

DELVECCHIO, S. (2012) On the Use of Wavelet Transform for Practical Condition Monitoring Issues. *Advances in Wavelet Theory and Their Applications in Engineering, Physics and Technology*. InTech, Croatia.

DOS SANTOS, C.R. (2010). *Detecção de oscilações em malhas de controle*. Trabalho de Conclusão de Curso em Engenharia Elétrica, Universidade Federal de Sergipe, São Cristóvão-SE, Brasil.

ELLIS, R. C.; Li, X.; RIGGS, J. B. (1998). Modeling and Optimization of a Model IV Fluidized Catalytic Cracking Unit. *AIChE Journal*, **44**(9): 2068-2079.

GARCÍA, C.E.; MORSHEDI, A.M. (1986). Quadratic programming solution of dynamic matrix control (QDMC). *Chemical Engineering Communications*, **46**(1-3):73-87.

GUO, Z.; SHEN, J.; XIE, L.; CHEN, X.; SU, H. (2014). Automatic detection of multiple oscillations by wavelet analysis. *Computers and Electrical Engineering*, **40**(7):2167-2177

GUO, Z.; XIE, L.; HORCH, A.; WANG, Y.; SU, H.; WANG, X. (2014). Automatic Detection of Nonstationary Multiple Oscillations by an Improved Wavelet Packet Transform. *Industrial e Engineering Chemistry Research*. **53**(40):15686-15697.

HUANG, C.S.; SU, W.C. (2007). Identification of modal parameters of a time invariant linear system by continuous wavelet transformation. *Mechanical Systems and Signal Processing*, **21**(4): 1642-1664.

JELALI, M. (2013). *Control Performance Management in Industrial Automation*. Springer, London.

JIAO, X. (1999). *Paper machine data analysis and optimization using wavelets*. MSc Thesis, The University of British Columbia, Vancouver, Canada.

JIN, J.; SHI, J. (2001). Automatic feature extraction of waveform signals for in-process diagnostic performance improvement. *Journal of Intelligent Manufacturing*, **12**(3): 257-268.

JONES, M. (2006). *Closed loop control performance monitoring*. MSc Thesis, University of Pretoria, South Africa.

KARRA, S.; KARIM, M.N. (2009). Comprehensive methodology for detection and diagnosis of oscillatory control loops. *Control Engineering Practice*, **17**(8): 939-956

KARRA, S.; KARIM, M.N. (2010). *Oscillation Root-cause Detection and Quantification Under Multiple Faults*, pp 267-293, Springer, London.

KING, D. (1996). Engineering of Fluidized Catalytic Crackers. *Chevron Research and Technology Company*, Richmond, California, USA.

KUMAR, A.; TALE, S. (2015). Similarity Measurement Technique of Two ECG Signals Analysis and Pattern Classification. *International Journal of Electrical and Electronics Research*, **3**(3): 35-47.

LI, L.; QU, L.; LIAO, X. (2007). Haar wavelet for machine fault diagnosis. *Mechanical Systems and Signal Processing*, **21**(4): 1773-1786.

MATSUO, T. (2005). Application of Wavelet Transform to Control System Diagnosis. *The IEE Control and Automation Professional Network*, pp. 81-88.

MATSUO, T.; SASAOKA, H.; YAMASHITA, Y. (2003). Detection and Diagnosis of Oscillations in Process Plants. *Lecture Notes in Computer Science*, **2773**: 1258-1264.

MATSUO, T.; TADAKUMA, I.; THORNHILL, N.F. (2004). Diagnosis of a unit-wide disturbance caused by saturation in a manipulated variable. In: *Proceedings of the IEEE Advanced Process Control Applications for Industry Workshop*, Vancouver, Canada.

MISITI, M.; MISITI, Y.; OPPENHEIM, G.; POGGI, J.M. (2008). *Wavelet toolbox™ 4 User's Guide*. The Mathworks, USA.

MORO, L. F. L.; ODLOAK, D. (1995). Constrained multivariable control of fluid catalytic cracking converters. *Journal of Process Control*, **5**(1): 29-39.

NEGRI, T.T. (2012). *Reconhecimento de padrões via Wavelets: Aplicação no monitoramento de estruturas a partir do efeito do multicaminho proveniente de sinais de satélites GPS*. Dissertação de Mestrado, Faculdade de Ciências e Tecnologia da UNESP, Presidente Prudente, Brasil.

PENG, Z.K.; CHU, F.L. (2004). Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography. *Mechanical Systems and Signal Processing*, **18**(2): 199-221.

PROTÁZIO, J.M.B. (2002). *Análise Wavelet aplicada a sinais geofísicos*. Dissertação de Mestrado, Universidade Estadual de Campinas, Brasil.

QIN, S.J.; BADGWELL, T.A. (2003). A survey of industrial model predictive control technology. *Control Engineering Practice*, **11**(7): 733-764.

RODRIGUES, A.A.L. (2011). *Diagnóstico de fontes de perturbação em plantas industriais*. Dissertação de Mestrado, Universidade Federal do Espírito Santo, Brasil.

SELVANATHAN, S. (2010). *Frequency-domain based approaches to the diagnosis of poor control loop performance*. Ph.D Thesis, Indian Institute of Technology Madras, Chennai, Índia.

SELVANATHAN, S.; MORTEN, H. (2011). Use of cross wavelet transform for diagnosis of oscillations due to multiple sources. In: *Proceedings of the 18th International Conference on Process Control*, Tatranská Lomnica, Slovakia.

SETH, A.K. (2010). A MATLAB toolbox for Granger causal connectivity analysis. *Journal of Neuroscience Methods*, **186**(2): 262-273.

SHINDE, A.D. (2004). *A Wavelet Packet Based Sifting Process and Its Application for Structural Health Monitoring*. MSc Thesis, Faculty of Worcester Polytechnic Institute, USA.

SRINIVASAN R.; RAGHUNATHAN R. (2005). Control Loop Performance Assessment. 1. A Qualitative Approach for Stiction Diagnosis. *Ind. Eng. Chem. Res.*, **44**(17): 6708-6718.

TANNUS, D.D. (2013). *Identificação de parâmetros modais de sistemas estruturais utilizando a transformada de wavelet*. Trabalho de Conclusão de Curso em Engenharia Elétrica, Universidade Federal de Sergipe, São Cristóvão-SE, Brasil.

THE MATHWORKS, Inc. (2010). *Matlab – The Language of Technical Computing*, v. 2010a. Natick, MA.

THORNHILL, N.F.; HÄGGLUND, T. (1997). Detection and diagnosis of oscillation in control loops. *Control Eng. Practice*, **5**(10): 1343-1354.

THORNHILL, N.F.; HORCH, A. (2007). Advances and new directions in plant-wide disturbance detection and diagnosis. *Control Engineering Practice*, **15**(10): 1196-1206.

THORNHILL, N.F.; HUANG, B.; ZHANG, H. (2003). Detection of multiple oscillations in control loops. *Journal of Process Control*, **13**(1): 91-100.

UZINSKI, J.C. (2013). *Momentos nulos e regularidade wavelet na detecção de falhas em sinais*. Dissertação de Mestrado, Universidade Estadual Paulista, Brasil.

WANG, W.J. (1996). Wavelet Transform in Vibration Analysis for Mechanical Fault Diagnosis. *Shock and Vibration*, **3**(1): 17-26.

YUAN, T.; QIN, S.J. (2014). Root cause diagnosis of plant-wide oscillations using Granger causality. *Journal of Process Control*, **24**(2): 450-459.

ZANIN, A. C.; DE GOUVEA, M. T.; ODLOAK, D. (2002). Integrating real-time optimization into the model predictive controller of the FCC system. *Control Engng Practice*, **10**(8): 819-831.

ZHANYANG X.; ZHAN C.; SHUNYI Z. (2009). A new non-invasive method for valve stiction detection using wavelet technology. *Journal of Electronics*, **26**(5): 673-680.

ZUQUI JR, G.C.; MUNARO, C.J. (2015). Fault detection and isolation via Granger causality. In: *Anais do XII Simpósio Brasileiro de Automação Inteligente (XII SBAI)*, Natal, Brasil.